

تهیه نقشه کاربری اراضی دشت عباس ایلام با استفاده از روش‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حداقل احتمال

* صالح آرخی

استادیار گروه جغرافیا، دانشکده علوم انسانی، دانشگاه گلستان، گرگان، ایران

تاریخ دریافت: ۱۳۹۳/۰۱/۲۹ تاریخ پذیرش: ۹۳/۱۱/۲۸

چکیده

یکی از ضروری‌ترین اطلاعات مورد نیاز مدیران و متولیان منابع طبیعی، نقشه‌های کاربری اراضی می‌باشد. در پژوهش حاضر، به منظور تهیه نقشه کاربری اراضی دشت عباس از داده‌های رقومی سنجنده (۱۳۸۶) ETM⁺ استفاده شد. ابتدا تصویر با میانگین خطای مربعات ۰/۴۷ پیکسل تصحیح هندسی شد. جهت طبقه‌بندی تصویر از روش‌های طبقه‌بندی شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حداقل احتمال استفاده شد. در نهایت، نقشه پوشش اراضی منطقه به چهار کلاس اراضی کشاورزی، مرتع فقیر، اراضی بایر و پهنه‌های ماسه‌ای طبقه‌بندی گردید. برای ارزیابی صحت نتایج طبقه‌بندی، نقشه تولیدی با نقشه واقعیت زمینی ایجاد شده از طریق GPS و بازدید صحراوی مورد مقایسه قرار گرفت. نتایج نشان داد، روش شبکه عصبی مصنوعی به ترتیب با صحت کلی ۹۸/۳۷ درصد و ضریب کاپای ۰/۹۷ نسبت به روش ماشین بردار پشتیبان (با صحت کلی ۹۲/۳۶ درصد و ضریب کاپای ۰/۸۷) و حداقل احتمال (با صحت کلی ۸۱/۴۲ درصد و ضریب کاپای ۰/۷۳) عملکرد بهتری در تهیه نقشه کاربری اراضی داشته است. مطالعه حاضر نشان داد که روش طبقه‌بندی شبکه عصبی، قابلیت تهیه نقشه پوشش اراضی را با صحت بالا دارد.

واژگان کلیدی: الگوریتم، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، حداقل احتمال، دشت عباس، استان ایلام.

*نویسنده مسئول: arekhi1348@yahoo.com

مقدمه

با توجه به این که هدف اساسی فناوری سنجش از دور شناسایی و تفکیک پدیده‌های زمین است، بنابراین طبقه‌بندی تصاویر ماهواره‌ای مهم‌ترین مرحله تفسیر اطلاعات ماهواره‌ای محسوب می‌شود. روش‌های مختلفی برای تهیه نقشه پوشش اراضی وجود دارد که هر کدام دارای مزایا و محدودیت‌هایی هستند. انتخاب روش به هدف مطالعه و داده‌های در دسترس بستگی دارد. امروزه، از متداول‌ترین و دقیق‌ترین روش‌های طبقه‌بندی مورد استفاده برای این منظور، می‌توان به روش‌های آماری نظری طبقه‌بندی حداکثر احتمال و حداقل فاصله اشاره کرد. اما مشکلاتی از قبیل فرضیات مورد نیاز در این روش‌ها چون توزیع نرمال داده‌ها، منجر به ایجاد روش‌های جدیدتر و استفاده بیشتر از آنها شده است. روش‌های دیگر طبقه‌بندی، از جمله شبکه‌های عصبی، توجه زیادی را به خود جلب کرده‌اند. به دلیل ماهیت غیرپارامتریک شبکه‌های عصبی و قابلیت شان برای بهره‌گیری از مثال‌ها و توانایی تعمیم آنها، برای طبقه‌بندی نظارت شده مناسب قلمداد می‌شوند. علاوه بر این، در بسیاری از مطالعات مقایسه‌ای، شبکه‌های عصبی پوشش اراضی را دقیق‌تر از روش‌های متداول موجود طبقه‌بندی کرده‌اند (فودی، ۲۰۰۰). در چند سال اخیر یک تکنیک جدید بر اساس تئوری یادگیری آماری با نام ماشین‌های بردار پشتیبان جهت طبقه‌بندی داده‌های سنجش از دور مورد استفاده واقع شده است (یوا و همکاران، ۲۰۰۸؛ دیکسون و کنند، ۲۰۰۸). در اصل، روش‌های SVM^۱ برای تشخیص متون موجود در تصاویر (تبديل استناد موجود به متن رایانه‌ی)، تشخیص رقومی دست نوشته و شناسایی صورت به کار برده شده است (وپنیک، ۱۹۹۵؛ جکیمز، ۱۹۹۹).

در زمینه طبقه‌بندی پوشش‌زمینی با استفاده از داده‌های سنجش از دور تحقیقات متعددی وجود دارد. اولین طبقه‌بندی پوشش سطح زمین در مقیاس جهانی با روش حداکثر احتمال توسط دفریس و توانشید^۲ (۱۹۹۴) و تهیه نقشه پوشش سطح زمین با قدرت تفکیک یک کیلومتر با استفاده از تصویر AVHRR^۳ با استفاده از روش طبقه‌بندی نظارت نشده توسط لولن و همکاران^۴ (۲۰۰۰) انجام گرفته است. به علت محدودیت‌های این روش‌ها، در سال‌های اخیر، رویکردهای طبقه‌بندی شبکه عصب مصنوعی و تصمیم‌گیری درختی که خصوصیات غیرخطی و غیرپارامتریک دارند، در سطح منطقه‌ای و

1- Support Vector Machine

2- Defries and Townshed

3- Advanced Very High Resolution Radiometer

4- Loveland

جهانی مورد استفاده قرار گرفتند. هانسن و همکاران^۱ (۱۹۹۶) از داده‌های NOAA/AVHRR برای تهیه نقشه پوشش سطح زمین در مقیاس جهانی و روش‌های حداکثر احتمال و طبقه‌بندی درختی استفاده کردند. در این بررسی دقت روش طبقه‌بندی درختی نسبت به حداکثر احتمال بهتر گزارش شده است. شبکه عصبی روش دیگری می‌باشد که به‌طور گسترده در طبقه‌بندی داده‌های سنجش از دور مورد بررسی واقع شده است. در شناسایی محدوده گسترش گلدم، مورتی و همکاران^۲ (۲۰۰۳) از این روش استفاده کردند که کارآمدی بهتری نسبت به روش حداکثر احتمال نشان داد. برای غلبه به مشکل ساختاری شبکه عصبی، روش آرتمپ فازی^۳ توسعه یافت که این روش می‌تواند منطق فازی و تئوری تشدید انطباقی را با هم تلفیق کند. گوپال و همکاران^۴ (۱۹۹۹) با استفاده از رویکرد آرتمپ فازی پوشش سطح زمین را در مقیاس جهانی طبقه‌بندی نموده‌اند. بوراک و همکاران^۵ (۱۹۹۹) روش‌های حداکثر احتمال، درخت تصمیم‌گیری و شبکه عصب مصنوعی آرتمپ فازی را مقایسه نموده و نتیجه گرفتند که روش طبقه‌بندی درختی می‌تواند بیشتر اطلاعات تصویر را حفظ نموده و نسبت به نمونه تعليمی حساس نمی‌باشد، در حالیکه آرتمپ فازی نسبت به درخت تصمیم‌گیری و حداکثر احتمال دقت بالاتری دارد. ماشین بردار پشتیبان یکی دیگر از روش‌های طبقه‌بندی تصاویر ماهواره‌ای است که در این تحقیق مورد بررسی قرار گرفته است. روش ماشین‌های بردار پشتیبان یک روش کلاسیک‌بندی الگو است که اولین بار توسط وپنیک^۶ (۱۹۹۵) معرفی شد. دیکسون و کن داد^۷ (۲۰۰۸)، از الگوریتم ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای استفاده کردند و نتایج این طبقه‌بندی کننده را با الگوریتم شبکه عصبی مقایسه کردند و نتیجه گرفتند که الگوریتم ماشین‌های بردار پشتیبان دارای دقت و صحت بالای در امر طبقه‌بندی می‌باشد.

امیری و همکاران (۲۰۰۷) از سه روش فازی، شبکه عصبی و کمترین فاصله برای طبقه‌بندی تصویر ماهواره‌ای Quickbird به سه طبقه پوشش گیاهی، منطقه شهری و آب استفاده کردند، و به این نتیجه رسیدند که دقت طبقه‌بندی با روش شبکه عصبی در مقایسه با دو روش دیگر در منطقه مورد مطالعه

1- Hanson

2- Murthy

3- Fuzzy Artmap

4- Gupal

5- Borak

6-Vapnik

7- Dixon and Candade

بیشتر است. مس^۱ (۲۰۰۳) برای طبقه‌بندی پوشش و کاربری اراضی منطقه تالابی ترمینوس در جنوب شرقی مکزیک، شبکه عصبی پرسپترون چند لایه‌ای (MLP) والگوریتم پس انتشار را مورد استفاده قرار داد. ورودی‌های شبکه عصبی باندهای طیفی دو، سه، چهار، پنج و هفت سنجنده^۲ ETM⁺ ماهواره لنdest بود و شش طبقه پوشش اراضی به عنوان خروجی تهیه شد. صحبت طبقه‌بندی ۸۲ درصد گزارش شد (مس، ۲۰۰۳). Lizarazo^۲ (۲۰۰۶)، برای طبقه‌بندی کاربری اراضی منطقه شهری بوگوتا در کلمبیا از روش طبقه‌بندی درخت تصمیم‌گیری، شبکه عصبی و حداقل احتمال استفاده کرد. برای انجام طبقه‌بندی، تصویر Quickbird به کار برده شد و نقشه کاربری اراضی با نه طبقه ایجاد شد. صحبت طبقه‌بندی کاربری اراضی برای روش‌های درخت تصمیم‌گیری، شبکه عصبی و حداقل احتمال به ترتیب ۷۴، ۶۵ و ۴۰ درصد برآورد گردید (Lizarazo، ۲۰۰۶). آرخی و ادیب نژاد (۲۰۱۱)، در تحقیقی به ارزیابی کارایی الگوریتم‌های ماشین بردار پشتیبان جهت طبقه‌بندی کاربری اراضی با استفاده از داده‌های ماهواره‌ای ETM⁺ لنdest (در سال ۲۰۰۲) در حوزه سد ایلام پرداختند. در این تحقیق طبقه‌بندی با استفاده از روش ماشینهای بردار پشتیبان، بصورت خودکار و با استفاده از چهار نوع کرنل خطی، چندجمله‌ای، شعاعی و حلقوی اجرا شده است. صحبت طبقه‌بندی کاربری اراضی برای روش‌های ماشین بردار پشتیبان و حداقل احتمال به ترتیب ۹۵، ۸۵ درصد و ضریب کاپا به ترتیب ۰/۷۹ و ۰/۹۴ برآورد گردید.

هدف اصلی پژوهش حاضر، تهیه نقشه کاربری اراضی منطقه دشت عباس با استفاده از تصویر سنجنده لنdest، ۱۳۸۶، و به کارگیری سه روش شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حداقل احتمال و مقایسه کارایی این سه روش در طبقه‌بندی پوشش اراضی منطقه مورد مطالعه است.

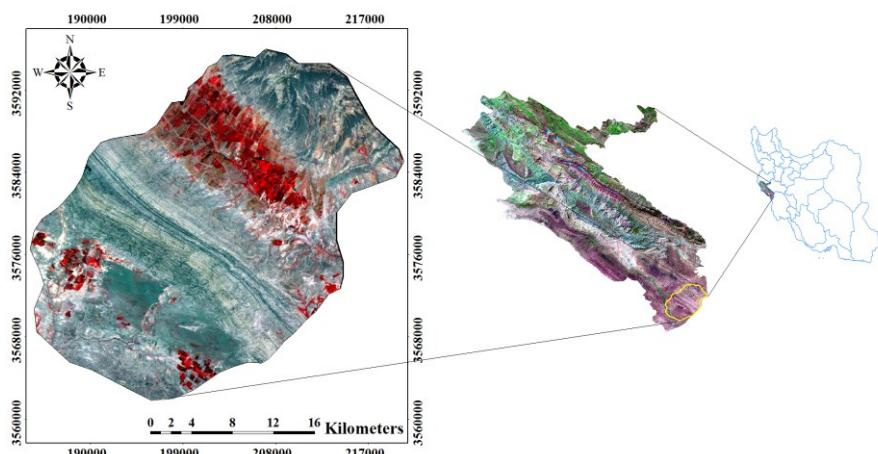
مواد و روش‌ها

معرفی منطقه مورد مطالعه: منطقه دشت عباس در جنوب تا جنوب شرقی استان ایلام قرار گرفته و دارای مختصات جغرافیایی^۱ ۶۴°۴۷' تا ۴۸°۰۳' طول شرقی و^۲ ۱۴°۳۲' تا ۴۶°۳۲' عرض شمالی می‌باشد (شکل ۱). براساس بررسی‌های انجام شده توسط سازمان هوافضای ایران، این منطقه از نظر طبقه‌بندی اقلیمی کوپن، جزء اقلیم خشک با تابستان‌های گرم به حساب می‌آید. متوسط بارندگی ۲۷۱/۵ میلی

1- Mas

2- Lizarazo

متر، متوسط تبخیر سالیانه ۳۵۵۳ میلی متر در تشت و ۳۱۷ میلی متر در سطح آزاد بوده و متوسط دمای سالیانه ۲۵/۶ درجه سانتی گراد می باشد. مساحت منطقه مورد مطالعه ۷۷۶۴۶ هکتار برآورده شده است. در ضمن ارتفاع منطقه از ۵۰ تا ۳۶۱ متر بالای سطح دریاهای آزاد متغیر است.



شکل ۱- موقعیت کشوری و استانی منطقه مورد مطالعه

مواد استفاده شده: در این تحقیق از تصویر ماهواره‌ای لندست (ETM⁺) به تاریخ ۱۳۸۶/۴/۳، و قدرت تفکیکی مکانی ۳۰ متر، نقشه‌های توپوگرافی ۱:۲۵۰۰۰ رقومی و کاغذی سازمان نقشه‌برداری و دیگر اطلاعات رقومی و چاپ شده موجود منطقه، نرم افزارهای سنجش از دور ۵/۴ ENVI، ۱۷ IDRISI Ands و نرم افزار سیستم اطلاعات جغرافیایی ArcGIS ۳/۹ استفاده گردید.

روش تحقیق

مرحله پیش پردازش داده‌ها، یکی از مهمترین مراحل در پردازش تصاویر است؛ چرا که تمامی محاسبات بعدی بر اساس تصویر تولیدی در این مرحله انجام می گیرد. نوع و نحوه انجام این عملیات بسته به عوامل مختلفی چون نوع داده‌های مورد استفاده و هدف تحقیق، متغیر خواهد بود. به طور کلی منظور از تصحیح هندسی یک تصویر، تغییر سیستم مختصات اجزای سازنده تصویر و انطباق آن با نقشه‌های نظری و یا تصویری است که قبل از روی آن تصحیح هندسی صورت گرفته است. در این

تحقیق، تصویر ماهواره‌ای ETM⁺ لندست (۱۳۸۶) منطقه برای تعیین کاربری اراضی مورد استفاده قرار گرفت. تصحیح هندسی این تصویر با استفاده از بسته نرم‌افزاری ENVI ۵/۴ و به کار بردن تبدیل چندجمله‌ای^۱، بر اساس سیستم تصویر UTM زمین مرجع شد. مختصات نقاط کنترل زمینی از روی نقشه توپوگرافی ۱:۵۰۰۰۰، تصاویر ماهواره‌ای گوگل ارث و نقاط مرجع زمینی با استفاده از GPS بدست آمدند. در پایان، روش نمونه‌گیری مجدد نزدیکترین همسایه برای تعیین مقادیر جدید پیکسل به کار گرفته شد.

تهیه نمونه‌های تعلیمی و طبقه‌بندی: انتخاب نمونه‌های تعلیمی مورد نیاز برای طبقه‌بندی کلاس‌های مختلف در منطقه با شناخت از منطقه و با استفاده از اطلاعات جانبی و استفاده از تصویر رنگی مرکب باند دو، سه و چهار تصویر TM ماهواره لندست ۵ به ترتیب رنگ آبی، سبز و قرمز صورت گرفت. انتخاب این تصویررنگی کاذب، صرفاً جهت شناسایی کلاس‌های مورد نظر و انتخاب بهترین نمونه‌های تعلیمی بوده است. برای این منظور در منطقه مورد مطالعه به فراخور سهم هر طبقه تعداد مناسبی نمونه تعلیمی به طور تصادفی با استفاده از بررسی‌های میدانی، تصویر گوگل ارث^۲ و تصویر رنگی کاذب انتخاب گردیدند. در انتخاب نمونه‌های تعلیمی سعی شد ضمن اینکه معرف خوبی برای طبقات مورد نظر باشد، از پراکنش خوبی نیز برخوردار باشد. با توجه به بازدید میدانی و تصویر ماهواره‌ای گوگل ارث مربوط به منطقه، مشاهده گردید که در سال ۱۳۸۶، چهار طبقه پوشش کشاورزی، مرتع فقیر، اراضی بایر و پهنه‌های ماسه‌ای وجود داشته است. به منظور حذف پیکسل‌های منفرد و پراکنده در سطح تصویر طبقه‌بندی شده و همچنین بدست آوردن تصویر مطلوب و با وضوح بیشتر، از فیلتر مد در اندازه ۵×۵ پیکسل استفاده شد.

ارزیابی صحت: ارزش و قابلیت استفاده از هر نقشه تولید شده به درجه صحت آن بستگی دارد و نقشه‌ها بدون تعیین صحت ارزش کاربردی کمی دارند. در تعیین صحت نقشه‌های یاد شده نیاز به اطلاعات زمینی یا مناطق آزمایشی می‌باشد. مناطق آموزشی در حقیقت شامل نواحی نمونه از کاربری‌های مورد نظر می‌باشد که معمولاً از طریق بازدیدهای میدانی و تصویر ماهواره‌ای گوگل ارث تهیه می‌گردند. معمولترین پارامترهای برآورد صحت شامل، صحت کل^۳، صحت تولیدکننده^۴، صحت

-
1. Polynomial Transformation
 2. Google Earth
 3. Overall accuracy
 4. Producer's Accuracy

صالح آرخی

کاربر^۱ و ضریب کاپا^۲ هستند (کونگلتون و گرین، ۱۹۹۳، ۱۹۹۹). در این مطالعه، برای ارزیابی صحت نقشه‌های طبقه‌بندی شده، با قطع دادن (مقایسه متناظر) نقشه‌های طبقه‌بندی شده با نقشه واقعیت زمینی حاصل از مطالعات میدانی، ماتریس خطای^۳ تشکیل شد و بر اساس آن صحت کل^۴ و ضریب کاپا^۵ محاسبه گردید.

نتایج و بحث

پس از تهیه تصویر ماهواره‌ای با استفاده از نقاط کنترل زمین، تصویر با خطای حدود ۰/۴۷ زمین مرجع گردید. پس از آماده‌سازی تصویر، با استفاده نمونه‌های تعلیمی جمع‌آوری شده از هر کاربری، تصویر با استفاده از سه روش اشاره شده در بالا طبقه‌بندی گردید. پس از طبقه‌بندی تصویر مذکور با استفاده از روش‌های شبکه عصبی، ماشین بردار پشتیبان و حداقل احتمال نتایج به صورت نقشه تهیه گردید (شکل‌های ۲، ۳ و ۴). در مرحله بعدی با انجام عملیات میدانی، تصاویر ماهواره‌ای گوگل ارث و نمونه‌برداری تصادفی از سطح منطقه مورد مطالعه، پارامترهای آماری ماتریس خطای گماشته شده و خطای حذف شده)، دقت تولیدکننده، دقت استفاده کننده، دقت کل و ضریب کاپا به شرح جدول‌های ۱، ۲ و ۳ استخراج گردید.

جدول ۱- ماتریس خطای طبقه‌بندی‌های مورد استفاده

کل	پهنه‌های ماسه‌ای	اراضی بایر	مرتع فقیر	کشاورزی	الگوریتم	
					طبقه‌بندی شبکه عصبی	مصنوعی
۷۸۳۱	۰	۴۴	۱۶	۷۷۱	کشاورزی	
۱۳۰۶۰	۲۱۸	۱۰۸	۱۲۷۳۴	۰	مرتع فقیر	
۲۸۴۵	۰	۲۸۱۲	۳۳	۰	اراضی بایر	
۲۵۳۲	۲۵۲۳	۰	۹	۰	پهنه‌های ماسه‌ای	
۲۶۲۶۸	۲۷۴۱	۲۹۶۴	۱۲۷۲۹	۷۷۱	کل	
طبقه‌بندی ماشین بردار پشتیبان						

- 1- User's Accuracy
2- Kappa Coefficient
3- Confuse Matrix
4- Overall Accuracy
5- Kappa Coefficient

نشریه مرتعداری، سال اول (۲)، ۱۳۹۳

۷۶۰۲	۰	۰	۰	۷۶۰۲	کشاورزی
۱۴۴۹۸	۱۳۷۷	۳۷۱	۱۲۷۲۰	۳۰	مرتع فقیر
۲۵۹۰	۰	۲۵۸۰	۹	۱	اراضی بایر
۱۳۸۲	۱۳۵۹	۰	۲۳	۰	پهنه‌های ماسه‌ای
۲۶۲۶۸	۲۷۳۶	۲۹۵۱	۱۲۷۵۲	۷۶۳۳	کل
طبقه‌بندی حداکثر احتمال					
۷۴۴۴	۰	۰	۱	۷۴۴۳	کشاورزی
۹۱۳۳	۲۷۶	۹۷	۸۶۱۵	۱۴۵	مرتع فقیر
۶۳۶۳	۲۴۶۵	۲	۳۷۱۸	۵	اراضی بایر
۶۳۶۳	۲۴۶۵	۲	۳۷۱۸	۱۷۸	پهنه‌های ماسه‌ای
۲۶۲۶۸	۲۷۴۱	۲۹۶۴	۱۲۷۹۲	۷۷۷۱	کل

زمانی که نتایج جداول ۱، ۲ بررسی می‌شود، چندین نتیجه گرفته می‌شود: (۱)، مشاهده شد که کلاس کشاورزی با دقت تولید کننده بالای ۹۵ درصد طبقه‌بندی شده است (با هر سه روش). این نشان دهنده قابلیت تفکیک طیفی بالا برای این کلاس است. (۲)، طبق نتایج مشاهده شد که پایین ترین دقت تولید کننده در مورد کلاس پهنه‌های ماسه ای بوده است. این کلاس با دقت تولید کننده ۴۹/۵۸ درصد برای تصویر این منطقه در حالت استفاده از روش حداکثر احتمال طبقه‌بندی شده است. در حالی که روش طبقه‌بندی شبکه عصبی مصنوعی و روش ماشین بردار پشتیبان به ترتیب با ۹۲/۰۵ درصد و ۸۹/۹۳ درصد دقت تولید کننده بهتر و بالاتری را برای این کلاس نشان دادند.

جدول ۲- مشخصات آماری صحت تولید کننده و استفاده کننده برای طبقه‌بندی تصویر ETM^+ با استفاده از سه روش طبقه‌بندی (درصد).

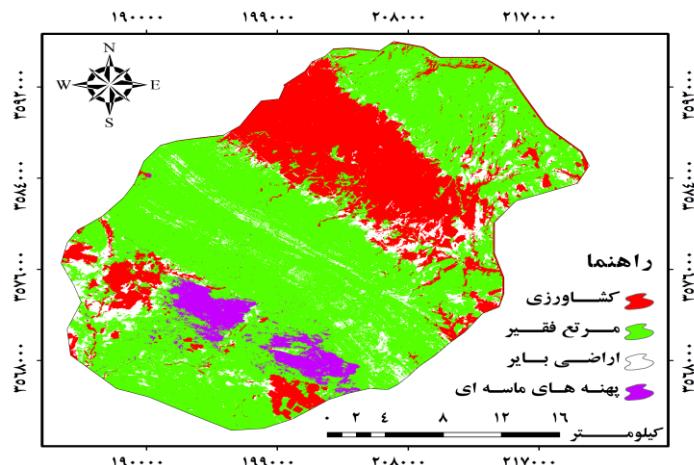
کلاس	روش‌ها						
	صحت		تولید کننده		استفاده		روش شبکه عصبی مصنوعی
	تولید	کننده (%)	استفاده	تولید	کننده (%)	استفاده	روش ماشین بردار پشتیبان
کشاورزی	۱۰۰	۹۹/۲۳	۹۷/۸۳	۹۷/۸۳	۱۰۰	۹۵/۷۸	۹۹/۹۹
مرتع فقیر	۹۹/۵۵	۹۷/۵۰	۹۹/۴۴	۸۷/۷۴	۸۷/۷۴	۶۷/۳۵	۹۴/۳۳
اراضی بایر	۹۴/۸۷	۹۸/۸۴	۸۷/۰۴	۹۹/۶۱	۹۹/۶۱	۹۷/۶۶	۸۷/۰۹
پهنه‌های ماسه‌ای	۹۲/۰۵	۹۹/۶۴	۸۹/۹۳	۹۸/۷۴	۹۸/۷۴	۴۹/۵۸	۳۸/۷۴

صالح آرخی

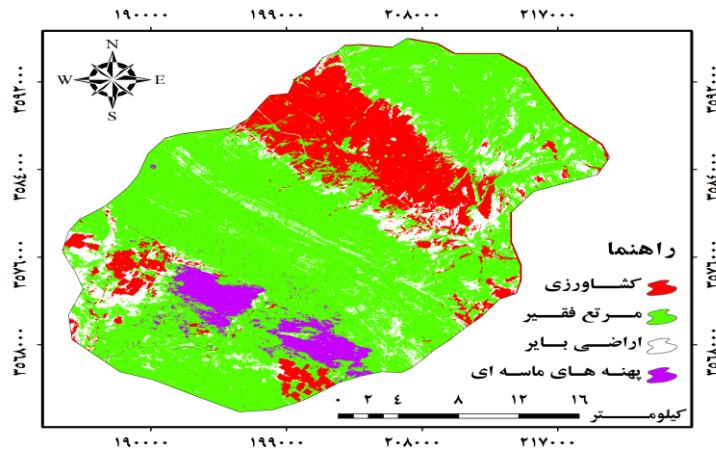
با توجه به نتایج جدول ۳ می‌توان گفت، روش شبکه عصبی مصنوعی به ترتیب با صحت کل ۹۸/۳۷٪ و ضریب کاپای ۰/۹۷ نسبت به روش ماشین بردار پشتیبان (با صحت کل ۹۲/۳۶٪ و ضریب کاپای ۰/۸۷) و حداقل احتمال (با صحت کل ۸۱/۴۲٪ و ضریب کاپای ۰/۷۳) عملکرد بهتری در تهیه نقشه کاربری اراضی داشته است.

جدول ۳- ارزیابی صحت طبقه‌بندی برای نقشه‌های کاربری استخراج شده از تصاویر ETM^+ با استفاده از سه روش طبقه‌بندی.

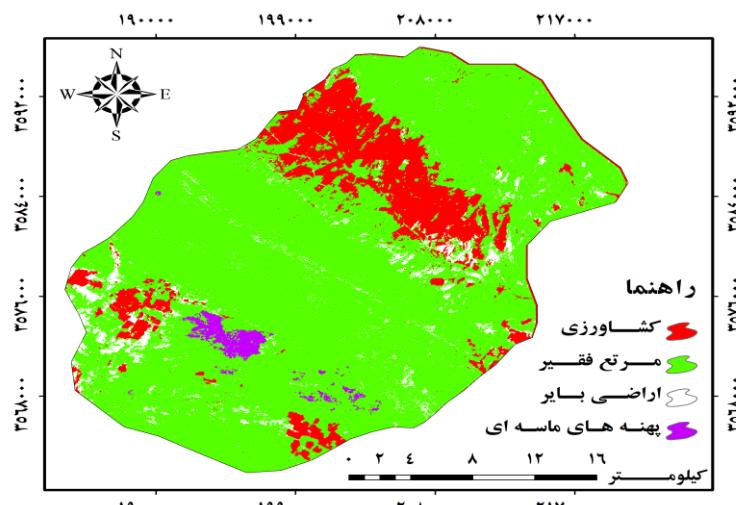
روش‌ها	صحت کل (%)	ضریب کاپا
روش شبکه عصبی مصنوعی	۹۸/۳۷	۰/۹۷
روش ماشین بردار پشتیبان	۹۲/۳۶	۰/۸۷
روش حداقل احتمال	۸۱/۴۲	۰/۷۳



شکل ۲- نقشه طبقه‌بندی الگوریتم شبکه عصبی مصنوعی



شکل ۳- نقشه طبقه‌بندی الگوریتم ماشین بردار پشتیبان



شکل ۴- نقشه طبقه‌بندی الگوریتم حداقل احتمال

نتیجه‌گیری

اطلاعات بهنگام و دقیق در مورد کاربری اراضی، موردنیاز تصمیم‌گیران و محققان در همه سطوح است. امروزه برای تهیه نقشه‌های کاربری زمین‌ها، استفاده از داده‌های ماهواره‌ای و روش‌های کمی در علم سنجش از دور بسیار معمول است و محققان و دانشمندان این علم در دهه گذشته به صورت گسترده آن را به کار برده‌اند. در این مطالعه، پس از تصحیح لازم و پیش‌پردازش‌های اولیه تصویر،

اقدام به طبقه‌بندی تصویر به سه روش فوق گردید، به عبارت دیگر کیفیت تصویر از نظر وجود خطاهای هندسی و رادیومتریک بررسی و تصحیح گردید. هدف این مطالعه تعیین کارایی روش شبکه عصبی مصنوعی جهت طبقه‌بندی کاربری اراضی و پوشش گیاهی با استفاده از داده چند طیفی در مقایسه با روش‌های طبقه‌بندی ماشین‌بردار پشتیبان و حداکثر احتمال بود.

طبق نتایج، روش شبکه عصبی مصنوعی به ترتیب با صحت کل ۹۸/۳۷ درصد و ضریب کاپای ۰/۹۷ نسبت به روش ماشین‌بردار پشتیبان (با صحت کل ۹۲/۳۶ درصد و ضریب کاپای ۰/۸۷) و حداکثر احتمال (با صحت کل ۸۱/۴۲ درصد و ضریب کاپای ۰/۷۳) عملکرد بهتری در تهیه نقشه کاربری اراضی داشته است. نتایج این پژوهش مشابه نتایجی است که برخی محققان در مناطق گوناگون به آن دسته یافته‌اند. به عنوان مثال، مندوza و همکاران (۲۰۰۴)، گزارش کردند که شبکه‌های عصبی مصنوعی، طبقه‌بندی تصویر را بهتر از روش‌های قدیمی آماری انجام می‌دهند، زیرا به داده‌هایی با توزیع پارامتریک نیاز ندارند (مندوza و همکاران، ۲۰۰۴). همچنین ندوشن و همکاران (۱۹۹۹)، نیازی و همکاران (۲۰۱۰) نشان دادند که روش طبقه‌بندی شبکه عصبی، نسبت به طبقه‌بندی حداکثر احتمال قابلیت تهیه نقشه پوشش اراضی را با صحت بالا دارد. اما با نتایج تحقیق یوسفی و همکاران (۲۰۱۱) که به مقایسه الگوریتم‌های مختلف طبقه‌بندی تصاویر ماهواره‌ای در تهیه نقشه کاربری اراضی شهرستان نور پرداختند، مخالف است. آنها به این نتیجه رسیدند که روش طبقه‌بندی ماشین‌بردار پشتیبان با میانگین ضرایب کلی و کاپا به ترتیب ۹۰/۹۴ درصد و ۹۵/۰۳ نسبت به روش‌های دیگر همچون شبکه عصبی و حداکثر احتمال دارای صحت بالاتری است. بالاخره، مخالف نظر دیکسون و کن داد (۲۰۰۸)، که از الگوریتم ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای استفاده کردند و نتایج روش طبقه‌بندی فوق را با الگوریتم شبکه عصبی مقایسه کردند و نتیجه گرفتند که الگوریتم ماشین‌های بردار پشتیبان دارای صحت بالاتری نسبت به شبکه عصبی مصنوعی در امر طبقه‌بندی می‌باشد. بنابراین می‌توان گفت طبقه‌بندی شبکه عصبی مصنوعی، روشنی مناسب برای تهیه نقشه پوشش و کاربری اراضی به شمار می‌آید که قابلیت طبقه‌بندی با صحت بالا را دارد. گرچه نتایج این تحقیق نشان می‌دهد که استفاده از روش شبکه عصبی، صحت بالاتری در مقایسه با روش طبقه‌بندی ماشین‌بردار پشتیبان و حداکثر احتمال ارائه می‌دهد، اما دو روش دیگر نیز طبق صحت کل و ضریب کاپا حاصله برای طبقه‌بندی پوشش اراضی مناسب است و در این مطالعه، صحت رضایت بخشی را ارائه دادند.

منابع

1. Alavi Paneh, S.k. and Masoudy, M. 1991. Preparing land use map using Landsat TM satellite imags and GIS (Case Study: Mohak region, Fars province). Journal of Agriculture and Natural Resources Sciences. 1:65-76.
2. Alavi Paneh, S.K. and Ahsani, A. 1993. Inverstigating desertification and Meghan playa lands changes with use of multi-temporal and multispectral satellite images. Desert Journal. 9(1): 143-154.
3. Amiri, A., Chavooshi, H. and Amini, J. 2007. Comparison of Three Satellite Image Classification: Fuzzy, Neural Network and Minimum Distance, Geomatic Conference, National Cartographic Center, Tehran.
4. Arekhi, S. and Adibnajat, M. 2011. Efficiency assessment of the Support Vector Machines for land use classification using Landsat ETM+ data (Case study: Ilam Dam Catchment), Iranian Journal of Range and Desert Reseach. 18(3): 420-440.
5. Borak, J.S. and Strahler, A.H. 1999. Feature selection and land cover classification of a MODIS-like dataset for a semiarid environment. International Journal of Remote Sensing. 20: 919-938.
6. Congalton, R.G. and Green, K. 1993. A practical look at the sources of confusion in error matrix generation. Photogrammetric Engineering and Remote Sensing. 59: 641–644.
7. Congalton, R.G. and Green, K. 1999. Assessing the accuracy of remotely sensed data: principles and practices. Boca Raton: Lewis Publishers.
8. DeFries, R.S. and Townshed, J.G. 1994. NDVI derived land cover classification at a globe scale. International Journal of Remote Sensing. 5: 3567-3586.
9. Dixon, B. and Candade, N. 2008. Multispectral land use classification using neural networks and support vector machines: one or the other, or both?, International Journal of Remote Sensing. 29: 1185–1206.
10. -ENVI User's Guide. 2008. ENVI On-line Software User's Manual, ITT Visual Information Solutions.
11. Foody, G.M. 2000. Mapping Land Cover from Remotely Sensed Data with a Softened Feedforward Neural Network Classification, Journal of Intelligent and Robotic Systems. 29: 433–449.
12. Gopal, S., Woodcock, C.E. and Strahler, A.H. 1999. Fuzzy Neural Network Classification of Global Land Cover from a 1o AVHRR DataSet. Remote Sensing of Environment. 67: 230-243.
13. Hanson, M.C., Dubayah, R. and Defries, R. 1996. Classification trees: an alternative to traditional land cover classifiers. International Journal of Remote Sensing. 17:1075-1081.
14. Joachims, T. 1999. Making large scale SVM learning practical. In Advances in Kernel Methods-Support Vector Learning, pp.169-184.

15. Karimi, Y., Orasher, S.O., Patel, R.M. and Kim, S.H. 2006. Application of support vector machine technology for weed and nitrogen stress detection in corn, *Computers, Electronics in Agriculture*. 51: 99-109.
16. Kavzoglu, T. and Colkesen, I. 2009. A kernel functions analysis for support vector machines for land cover classification, *International Journal of Applied Earth Observation and Geoinformation*. 11: 352-359.
17. Keuchel, J., Naumann, S., Heiler, M. and Siegmund, A. 2003. Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data, *Remote Sens. Environ.* 86: 53–541.
18. Knorn, J., Rabe, A., Radloff, V.C., Kuemmerle, T., Kozak, J. and Horstert, P. 2009. Land cover mapping of large areas using chain classification of neighboring Landsat satellite images, *Remote Sens. Environ.* 113: 957-964.
19. Koetz, B., Morsdoff, F., Linden, S., Curt, T. and Allogower, B. 2008. Multi-source land cover classification for forest fire management based on imaging spectrometry and LiDAR data, *Forest Ecology and Management*. 256 (3): 263-271.
20. Lizarazo, I. 2006. Urban Land Cover and Land Use Classification Using High Spatial Resolution Images and Spatial Metrics, *Proceedings of the 2nd Workshop of the EARSeL SIG on Land Use and Land Cover*. 292-298.
21. Loveland, T.R., Reed, B.C., Brown, J.F., Ohlen, D.O., Zhu, Z., Yang, L. and Merchant, J.W. 2000. Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data. *International Journal of Remote Sensing*. 21: 1303-1330.
22. Mas, J.F. 2003. An Artificial Neural Networks Approach to Map Land Use/cover Using Landsat Imagery and Ancillary Data, *Proceedings of the International Geosciences and Remote Sensing Symposium IEEE IGARSS 2003*, Vol. VI, pp. 3498-3500, Toulouse, France.
23. Mendoza, E.H., Santos, J.R., Santo Rosa, A.N.C. and Silva, C.N. 2004. Land Use/land Cover Mapping in Brazilian Amazon Using Neural Network with ASTER/TERRA data, *ISPRS*, <http://www.isprs.org/istanbul2004/comm7/papers/24.pdf>.
24. Murthy, C.S., Raju, P. and Bardrinath, K. 2003. Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks. *INT. J. Remote Sensing*. 24(23): 4871-4890.
25. Pal, M. and Mather, P.M. 2004. Assessment of the effectiveness of support vector machines for hyperspectral data, *Future Generation Computer Systems*. 20: 1215–1225.
26. Niazi, Y., Aktasasy, M.R., Makekhi Najat, H., Hossaini, Z. and Morshady, J. 2010. Comparing two methods of Maximum Likelihood and Nural Network in extracting land use map in ilam Dam watershed. *Journal of Geography and development*. 20: 119-132.

27. Nadoshan, M., Safaniyan, A. and Khajadin, S.J. 1999. Preparing lands cover of Arak City using Artificial neural network and maximum likelihood Classification. *Journal of Natural Geographic Researches*. 69: 83-98.
28. Petropoulos, G.P., Knorr, W., Scholze, M., Boschetti, L. and Karantounias, G. 2010. Combining ASTER multispectral imagery analysis and support vector machines for rapid and cost-effective postfire fire assessment: a case study from the Greek wildland fires of 2007, *Nat. Hazards Earth Syst. Sci.* 10: 305–317.
29. Sebastian, S. 2002. Multilayer perceptrons and back propagation Learning. 9,641, Lecture 4, September 17.
30. Vapnik, V.N. 1995. *The Nature of Statistical Learning Theory* (New York: Springer Verlag). 188.
31. Waske, B. and Benediktsson, J.A. 2007. Fusion of support vector machines for classification of multisensor data, *IEEE T. Geosci. Remote Sensing*. 45:12. 3858–3866.
32. Petropoulos, G.P., Kontoes, C. and Keramitsoglou, I. 2011. Burnt area delineation from a uni temporal perspective based on Landsat TM imagery classification using Support Vector Machines, *International Journal of Applied Earth Observation and Geoinformation*. 13: 70-80.
33. Yao, X., Tham, L.G. and Dai, F.C. 2008. Landslide susceptibility mapping based on support vector machine: a case study on natural slopes of Hong Kong, China. *Geomorphology*. 101: 572-582.
34. Yuan, F., Bauer, M.E., Heinert, N.J. and Holden, G.R. 2005. Multi-level Land Cover Mapping of the Twin Cities (Minnesota) Metropolitan Area with Multi-seasonal Landsat TM/ETM⁺ Data, *Geocarto International*. 20: 2. 5-14.
35. -Yousef, S., Tazeh, M., Mirezee, S., Moradi, H.R. and Tavanger, S.H. 2011. Comparison of different classification algorithms in satellite imagery to produce land use maps (Case study: Noor city), *Journal of Applied RS & GIS Techniques in Natural Resource Science*. 2(2): 15-25.
36. Yuan, H. 2002. Development and Evaluation of Advanced Classification Systems Using Remotely Sensed Data for Accurate Land-use/land-cover Mapping, Ph.D. Thesis, Department of Forestry, North Carolina State University.