

# کاربرد تجزیه و تحلیل طیف مخلوط نرمال شده (NSMA) جهت استخراج مناطق ساخته شده شهری و استفاده از آن در شبکه عصبی مصنوعی (MLP) برای پیش بینی رشد آتی شهر

بهرام جمعه زاده<sup>۱</sup>

سیروس هاشمی<sup>۲</sup>

علی درویشی بلورانی<sup>۳</sup>

مجید کیاورز<sup>۴</sup>

تاریخ دریافت مقاله: ۹۴/۰۷/۰۲

تاریخ پذیرش مقاله: ۹۴/۰۹/۰۲

\*\*\*\*\*

## چکیده

استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی متوسط به منظور شناسایی، نظارت و پیش‌بینی مناطق ساخته شده شهری در دهه‌های اخیر توسعه یافته است. مهم‌ترین گام در پیش‌بینی رشد مناطق شهری، استخراج ویژگی‌های سطح شهر با دقت و صحت بالا و مهم‌ترین چالش در این راه پیچیدگی عوارض شهری و مسئله پیکسل‌های مخلوط است. هدف از این تحقیق استفاده از مدل‌های تجزیه و تحلیل زیر پیکسل، برای استخراج عوارض سطحی شهر رشت به منظور پیش‌بینی برای تغییرات رشد آتی این شهر است. بدین منظور از سه تصویر لندست مربوط به سال‌های ۱۹۹۰ (سنجنده TM)، ۲۰۰۲ (سنجنده ETM+) و ۲۰۱۵ (سنجنده OLI/TIRS) و روش تجزیه و تحلیل طیف مخلوط نرمال شده (NSMA)، برای استخراج عوارض سطحی استفاده شد. برای طبقه‌بندی تصاویر از لایه‌های کسری پوشش به عنوان لایه‌های ورودی و عضوهای پایانی به عنوان نمونه‌های آموزشی و الگوریتم حداکثر احتمال به عنوان الگوریتم طبقه‌بندی کننده استفاده شد؛ که در نتیجه صحت کلی بالای ۹۹٪ و ضریب کاپای بالای ۰/۹۸ برای تصاویر سه دوره بدست آمد. به منظور پیش‌بینی رشد شهری با شبکه عصبی در این تحقیق از مدل پرسپترون چند لایه (MLP) با الگوریتم یادگیری پس انتشار (BP) استفاده شد. نتایج مقایسه خروجی مدل با نقشه طبقه‌بندی سال ۲۰۱۵، ضریب کاپای ۹۲٪، کاپای استاندارد ۸۹٪ و کاپای طبقه‌ای (برای طبقه ساخته شده) ۹۳٪، را نشان داد. مدل استفاده شده در این تحقیق در پیش‌بینی رشد مرزهای شهر موفق عمل کرده است، اما در پیش‌بینی مناطق ساخته شده انفرادی اطراف شهر صحت کمتری دارد.

واژه‌های کلیدی: تجزیه و تحلیل زیر پیکسل، تجزیه و تحلیل طیف مخلوط نرمال شده (NSMA)، پیش‌بینی رشد شهری، پرسپترون چندلایه.

\*\*\*\*\*

۱- دانشجوی کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی دانشکده جغرافیای دانشگاه تهران bahramjomezade.gis92@gmail.com

۲- دانشجوی کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی دانشکده جغرافیای دانشگاه تهران siroushashemi62@gmail.com

۳- استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی دانشکده جغرافیای دانشگاه تهران ali.darvishi@ut.ac.ir

۴- استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی دانشکده جغرافیای دانشگاه تهران kiavrz.majid@gmail.com

## مقدمه

با رشد سریع شهرها در سال‌های اخیر، درک ترکیبی و فیزیکی محیط شهری و پویایی آن به یک موضوع مهم تبدیل شده است و تکنیک‌های در حال توسعه مدل‌سازی پویا برای شبیه‌سازی و پیش‌بینی رشد شهری و تغییرات آینده چشم‌انداز در حوزه پژوهشی سنجش از دور شهری فعال شده است. اگر چه فن‌آوری سنجش از دور به طور بالقوه خود را علمی برای بررسی ترکیبات شهری و نظارت بر تغییرات آن در زمان معرفی کرده است (وو، ۲۰۰۴)، با این حال استخراج معنی‌دار معیارهای کمی برای توصیف پوشش زمین شهری به عنوان یک چالش در برنامه‌های کاربردی سنجش از دور باقی‌مانده است، چرا که مناطق شهری چشم‌انداز پیچیده‌ای از سازه‌های ساخته شده و پوشش زمین تغییر یافته توسط انسان می‌باشند (یانگ، ۲۰۱۱ ص ۱۲۲).

در درون یک منطقه شهری، تجزیه و تحلیل تصویر به دلیل تنوع طیفی و مکانی بالای مواد ساخته شده که منجر به تعداد زیادی از «پیکسل‌های مخلوط»<sup>۱</sup> در مقیاس‌های فضایی مختلف شده و روش‌های سنتی طبقه‌بندی را محدود می‌سازد، مشکل است (فرانکی و همکاران، ۲۰۰۹؛ مین تو اوکین، ۲۰۰۹؛ وو، ۲۰۰۹). مشکل پیکسل مخلوط را می‌توان با توصیف چشم‌انداز با متغیرهای پیوسته به جای اختصاص کلاس‌های گسسته، (ونگ و لو، ۲۰۰۹) و یا مدل‌سازی هر پیکسل به عنوان در صدی از پوشش مصالح ساختمانی پوشش زمین شهری (هانسن، و همکاران، ۲۰۰۲)، برای بدست آوردن جزئیات بیشتر از حداقل رزولوشن پیکسل، اعمال کرد. یک چارچوب مفهومی برای تجزیه و تحلیل چشم‌اندازهای شهری مدل VIS است (راید، ۱۹۹۵)، که چشم‌انداز شهری را به عنوان ترکیبی از سه اجزای اساسی، علاوه بر آب: پوشش گیاهی (V)، سطوح غیرقابل نفوذ (I)، و خاک لخت (S) تجزیه می‌کند. تجزیه و تحلیل طیف مخلوط

(SMA)<sup>۲</sup> یک تکنیک برای بدست آوردن فراوانی زیر پیکسل از هر یک از اجزای پوشش زمین، در نتیجه توصیف چشم‌انداز شهری به عنوان سطوح پیوسته از اجزای V-I-S است (پاولو همکاران، ۲۰۰۷). در روش SMA فرض بر این است که (الف) یک چشم‌انداز مدلی مخلوط از چند اجزای اصلی طیفی (عضو پایانی<sup>۳</sup>)، می‌باشد و (ب) نتایج اندازه‌گیری هر یک از پیکسل‌ها را می‌توان به عنوان یک مدل خطی ترکیبی از طیف عضوهای پایانی، در نظر گرفت (رابرتز و همکاران، ۱۹۹۸؛ سونگ، ۲۰۰۵؛ پاول و همکاران، ۲۰۰۷). با استفاده از مدل مفهومی V-I-S، تحقیقات بعدی برای تعیین کمیت توزیع پوشش گیاهی، سطح غیرقابل نفوذ، و خاک در محیط‌های شهری، از جمله جی<sup>۴</sup> و جنسن<sup>۵</sup> (۱۹۹۹) و وو، موری<sup>۶</sup> (۲۰۰۳) برای ارزیابی درصد نفوذناپذیری سطوح شهری، اسمال<sup>۷</sup> (۲۰۰۲) برای استخراج پوشش گیاهی و گورشمین<sup>۸</sup> و همکاران (۲۰۱۵) برای استخراج کسری خاک انجام شده است. همچنین استفاده از مدل V-I-S در بهبود طبقه‌بندی کاربری / پوشش زمین شهری، بررسی شده است. راشد<sup>۹</sup> و همکاران (۲۰۰۱) ترکیب شهری قاهره، را به عنوان پوشش گیاهی، سطح غیر قابل نفوذ، خاک، و سایه توصیف کردند و نتیجتاً با اعمال طبقه‌بندی، جزئیات ترکیب شهری را بدست آوردند. فینن<sup>۱۰</sup> و همکاران (۲۰۰۲) تصاویر کسر V-I-S با استفاده از روش SMA با عضوهای پایانی انتخاب شده از عکس‌های هوایی در جنوب شرقی کوئینزلند، استرالیا، تولید کردند و پیشنهاد کردند که مدل بر اساس V-I-S بهتر از طبقه‌بندی سنتی بر پایه پیکسل انجام شده

2- Spectral mixture analysis

3- endmember

4- Ji

5- Jensen

6- Murray

7- Small

8- Guerschman

9- Rashed

10- Phinn

1- Mixed pixels

اخیر افزایش پیدا کرده است. از جمله استفاده از شبکه عصبی در طبقه‌بندی تصاویر و پیدا کردن الگوها در تصاویر ماهواره‌ای (سیرسان و همکاران، ۲۰۱۲؛ کریژوسکی و همکاران، ۲۰۱۲)، استفاده از شبکه عصبی برای بازسازی و پیش‌بینی تغییرات کاربری اراضی (وانگ و همکاران، ۲۰۱۵؛ قوش و همکاران، ۲۰۱۴) و استفاده از شبکه عصبی در پیش‌بینی رشد شهری مانند: طیبی و همکاران (۲۰۱۱) برای پیش‌بینی رشد مرزهای شهر تهران، پیجانوفسکی و همکاران (۲۰۱۴) برای پیش‌بینی رشد شهرهای ایالات متحده در مقیاس ملی و تریانتاکونستانیس و استانتاکیس (۲۰۱۵) برای پیش‌بینی رشد شهر آتن، که نتایج آنها نشان داد که مدل‌های شبکه عصبی توانسته اند به خوبی پیچیدگی‌های رشد مناطق شهری را مدل نمایند و بر صحت اعتبارسنجی این مدل‌ها نیز روز به روز افزوده شده است. هدف از این تحقیق استخراج کاربری/ پوشش زمین شهر رشت با استفاده از مدل طیف مخلوط نرمال شده (NSMA)، و سپس مدل کردن رشد شهر رشت و پیش‌بینی رشد آتی با استفاده از شبکه عصبی است.

#### منطقه مورد مطالعه

رشت فشرده‌ترین شهر ایران به لحاظ نسبت جمعیت به وسعت است. آب و هوای رشت از جمله آب و هوای معتدل کاسپین و شبه مدیترانه‌ای است که دارای تابستان‌های گرم و شرجی و زمستان‌های سرد و مرطوب است. ارتفاع این شهر از سطح دریا ۵ متر است. ویژگی‌های طبیعی، ارتباطی و گردشگری این شهر موجب افزایش جمعیت و توسعه فیزیکی این شهر شده است.

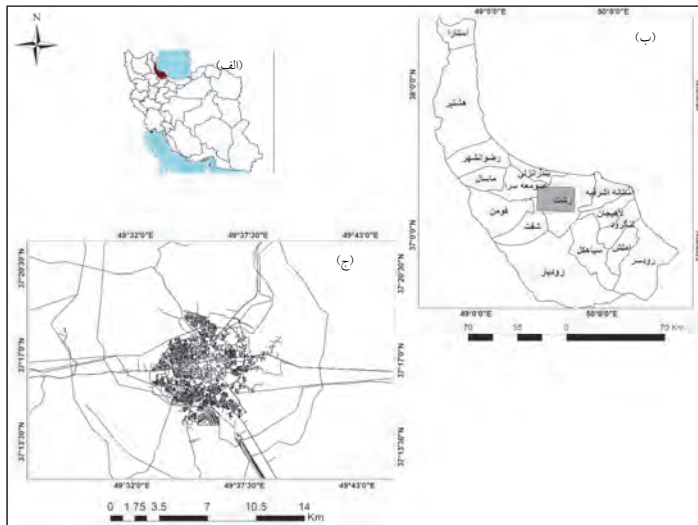
منطقه‌ی مورد مطالعه در این تحقیق محدوده مرز شهر رشت با حومه اطراف آن است. موقعیت منطقه‌ی مورد مطالعه در استان گیلان و شهرستان رشت در نگاره (۱) نمایش داده شده است.

است. لووونگ (۲۰۰۴) پوشش گیاهی سبز سطح غیرقابل نفوذ / خاک، و سایه برای توصیف شهری / روستایی محیط استفاده کردند و نشان دادند که مدل V-I-S به طور قابل توجهی می‌تواند به بهبود دقت و صحت طبقه‌بندی کاربری/پوشش زمین شهری، منتج شود. یکی از کاربردهای استخراج ویژگی‌های مناطق شهری پیش‌بینی برای تغییرات آتی است. تغییرات کاربری اراضی و گسترش شهری در نتیجه تعامل پیچیده عوامل بسیاری از جمله سیاست، مدیریت، اقتصاد، فرهنگ، رفتار انسان و محیط زیست بوجود می‌آید (پجانوفسکی و همکاران، ۲۰۰۲).

با توجه به پیچیدگی دینامیک فرآیند رشد شهری، تعریف یک مدل ریاضی برای توصیف چنین فرآیندی بسیار دشوار است. از این رو مدل‌سازی رشد شهری در طول دو دهه گذشته توسعه یافته است و مدل‌های زیادی با استفاده از ابزار هوش مصنوعی شامل، شبکه عصبی (NA)، سیستم‌های منطق فازی<sup>۱</sup> و سلول‌های خودکار<sup>۲</sup> در شبیه‌سازی رشد شهری، توسعه یافته است. برخلاف بسیاری از تکنیک‌های مدل‌سازی چند متغیره، شبکه‌های عصبی مصنوعی از روابط داده‌های ورودی مستقل هستند و بنابراین بی‌نیاز از هرگونه فرضیات مربوط به همبستگی مکانی و چند خطی از داده‌ها است (تریانتا و همکاران، ۲۰۱۵). شبکه عصبی مصنوعی متشکل از یک شبکه متصل از واحدهای پردازشی است که با اساسی‌ترین خواص نورون در مغز انسان مدل شده است. یکی از مزایای اصلی آن این است که مستقل از فرض توزیع آماری است. شبکه‌های عصبی به طور غیرخطی هستند و می‌توانند به عنوان یک تابع پیچیده ریاضی، داده‌های ورودی را به خروجی مورد نظر تبدیل کنند (کارل و سویاک، ۲۰۰۳). استفاده از شبکه عصبی مصنوعی در پردازش تصاویر ماهواره‌ای در دو دهه

1- Fuzzy logic

2- Cellular automata



نگاره ۱: موقعیت محدوده مورد مطالعه در  
 الف- ایران، ب-گیلان و ج- شهرستان رشت

#### داده‌های مورد استفاده

عضوهای پایانی را از طیف یک پیکسل اندازه‌گیری کند. خروجی SMA مجموعه‌ای از تصاویر که نشان دهنده‌ی کسری از هر عضو پایانی، با ارزش بین صفر و ۱ (صفر نشان دهنده «عدم وجود» و ۱ نمایندگی پوشش ۱۰۰٪) می‌باشد.

برای یک پیکسل، توصیف ریاضی SMA به شرح رابطه زیر است (آدامز و همکاران، ۱۹۸۶؛ اسمیت و همکاران، ۱۹۹۰؛ رابرتز و همکاران، ۱۹۹۹):

$$DN_i = \sum_{j=1}^K F_j \cdot DN_{i,j} + e_i \quad \text{رابطه (۱)}$$

که در آن مقدار اندازه‌گیری شده از یک پیکسل در باند  $i$ ، کسری از عضو پایانی  $J$  موجود در IFOV پیکسل،  $DN_{i,j}$  ارزش  $J$  عضو پایانی در باند  $i$ ، و  $e_i$  باقیمانده یا تفاوت بین ارزش مشاهده شده و مدل‌سازی شده برای باند  $i$ ،  $N$  تعداد باندها و  $K$  عضوهای پایانی موجود در مجموعه داده در مدل مخلوط می‌باشد.

مدل مخلوط محدودیت زیر را دارد که مجموع کسری عضو پایانی‌ها برای هر پیکسل باید ۱ باشد (یا ۱۰۰٪ پوشش) رابطه (۲).

$$\sum_{j=1}^K F_j = 1 \quad \text{رابطه (۲)}$$

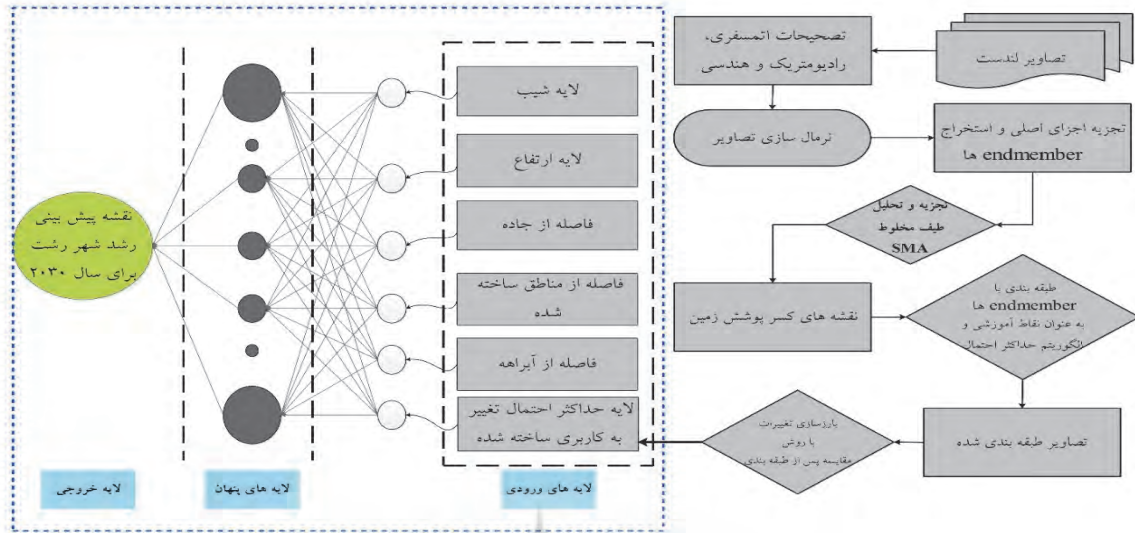
در این تحقیق از تصاویر ماهواره‌ای لندست ۵ سنجنده نقشه بردار موضوعی (TM)، لندست ۷ سنجنده نقشه بردار موضوعی ارتقا یافته (ETM+) و لندست ۸ سنجنده تصویربرداری عملیاتی زمین (OLI)، به ترتیب برای سال‌های ۱۹۹۰، ۲۰۰۲ و ۲۰۱۵ برای استخراج ویژگی‌های سطح زمین و نقشه کاربری اراضی منطقه مورد استفاده گرفته‌اند. از داده‌های جانبی نقشه توپوگرافی، نقشه رقوم‌ی ارتفاعی، نقشه راه‌های منطقه نیز برای تصحیح هندسی تصاویر و همچنین ورودی شبکه عصبی استفاده شد.

#### تجزیه و تحلیل طیف مخلوط (SMA)

عملاً در هر محیط شهری، سیگنال ثبت شده توسط یک سنجنده شامل بازتاب از چند نوع پوشش زمین است. پاسخ ثبت شده توسط سنجنده برای هر پیکسل، وزنی از مجموع طیف خالص از هر ماده در میدان دید لحظه‌ای (IFOV) پیکسل است.

هدف SMA این است که سهم نسبی هر یک از

- 1- Thematic Map
- 2- Enhanced Thematic Mapper Plus
- 3- Operational Land Imager



نگاره ۲: فرایند انجام پژوهش

خطای RMS پیکسل به پیکسل به طور مؤثر میانگین باقیمانده در تمام باندها است (رابطه (۳)):

خطای RMS پیکسل به پیکسل به طور مؤثر میانگین  $R_b$  بازتاب اصلی برای باند  $b$ ;  $\mu$  متوسط بازتاب برای آن پیکسل؛ و  $N$  تعداد کل باندها می باشد. پس از نرمال سازی، NSMA از روش زیر محاسبه می شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N e_i^2}{N}} \quad \text{رابطه (۳)}$$

$$\bar{R}_b = \sum_{i=1}^N \bar{f}_i R_{i,b} + e_b \quad \text{رابطه (۶)}$$

$$\sum_{i=1}^N \bar{f}_i = 1 \text{ and } \bar{f}_i^3 = 0 \quad \text{رابطه (۷)}$$

در رابطه (۶)  $\bar{R}_b$  بازتاب نرمال شده هر پیکسل در باند  $i$ ، و  $R_{i,b}$  بازتاب نرمال شده از عضو پایانی  $i$  در باند  $b$  برای آن پیکسل،  $\bar{f}_i$  کسر عضو پایانی  $i$  و  $e_b$  باقیمانده است. روند کلی این پژوهش در نگاره (۲) نشان داده شده است.

با در نظر گرفتن اینکه تنوع قابل توجهی در روشنایی برای طیف های پوشش زمین خالص و جو دارد، برای نزدیک کردن طیف های یک پوشش خاص به هم، در این مقاله از روش NSMA پیشنهادی وو (۲۰۰۴) استفاده شد. در این روش ابتدا میانگین تمام باندها محاسبه شده و سپس تک تک باندها بر میانگین تقسیم می شوند تا تفاوت روشنایی در طیف های یک ماده مشخص کم شود. ارزش های پیکسل با توجه به رابطه های ۴ و ۵ نرمال می شوند:

$$\mu = \frac{1}{N} \sum_{b=1}^N R_b \quad \text{رابطه (۴)}$$

$$\bar{R}_b = \frac{R_b}{\mu} \times 100 \quad \text{رابطه (۵)}$$

که در آن  $\bar{R}_b$  بازتاب نرمال شده باند  $b$  در پیکسل؛

پیش بینی گسترش شهر با شبکه عصبی پرسپترون چند لایه (MLP)

پرسپترون چند لایه با استفاده از یک الگوریتم یادگیری پس انتشار (BP) یکی از پر استفاده ترین مدل های شبکه عصبی است. یک شبکه معمولی MLP



روش NSMA و سپس پیش‌بینی رشد مناطق شهری با شبکه عصبی می‌باشد. فرایند انجام پژوهش در نگاره (۲) نشان داده شده است.

### بحث و نتایج

یکی از مشکلات استفاده از روش SMA، طیف‌های مرتبط با هر جزء پوشش زمین است که به دلیل روشنایی متفاوت، تغییر می‌کند (نگاره ۳- الف). سطوح نفوذناپذیر بیشترین تنوع روشنایی، با طیف‌های مختلف از بازتاب کم گرفته مانند آسفالت تا بازتاب‌های بالا مانند سطوح فلزی را شامل می‌شوند. طیف خاک با توجه به ترکیب خاک، اندازه دانه و میزان رطوبت تغییر می‌کند. طیف آب نیز به علت تفاوت در میزان آب مرداب‌ها و شالیزارها متفاوت است. طیف پوشش گیاهی ممکن است با توجه به مقدار کلروفیل و ویژگی‌های تاج پوشش تغییر کند.

با نرمال کردن تصویر همانطور که در نگاره (۳- ب) مشخص است، تفاوت در طیف‌های یک پوشش خاص بسیار کمتر شده است. در نگاره (۴)، کسرهای پوشش زمین بدست آمده از تصاویر نرمال شده ارائه شده است. کسرهای پوشش زمین به صورت پیوسته ویژگی‌های سطح زمین برای یک پوشش خاص را نمایش می‌دهند. در هر تصویر درصد وجود یک پوشش خاص در هر پیکسل مشخص شده است. برای مشخص کردن یک کلاس خاص در تصاویر کسر پوشش می‌توان از آستانه‌گذاری بروی تصاویر استفاده کرد. همچنین می‌توان این تصاویر را طبقه‌بندی نموده و کلاس‌های گسسته ایجاد کرد.

کلاس‌های بوجود آمده از تصاویر کسر پوشش زمین چند مزیت دارند. ابتدا انتخاب نمونه‌های آموزشی برای طبقه‌بندی از این تصاویر آسان‌تر و با دقت بیشتری انجام می‌شود. همچنین کاهش تصاویر چند طیفی در چند تصویر که هر یک بیانگر درصدی از یک پوشش

شامل یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان می‌باشد. MLP از طریق تجزیه و تحلیل رگرسیون ناپارامتری بین متغیرهای ورودی و یک متغیر وابسته با خروجی حاوی یک نورون خروجی، پیش‌بینی انجام می‌دهد (هسیه ۲۰۰۹). عملکرد MLP برای انجام اصلاح و تغییر وزن‌های مرتبط با هر نورون، شامل دو مرحله عمده است: انتشار رو به جلو و انتشار رو به عقب. در طول آموزش، هر نمونه لایه ورودی را تغذیه می‌کند و گره دریافت‌کننده سیگنال‌های وزن‌دار شده از تمام‌گره‌های متصل به آن در لایه پیشین را جمع می‌کند. به عبارت دیگر، ورودی‌ای که یک تک‌گره دریافت می‌کند با توجه به رابطه (۸) وزن‌دار می‌شود:

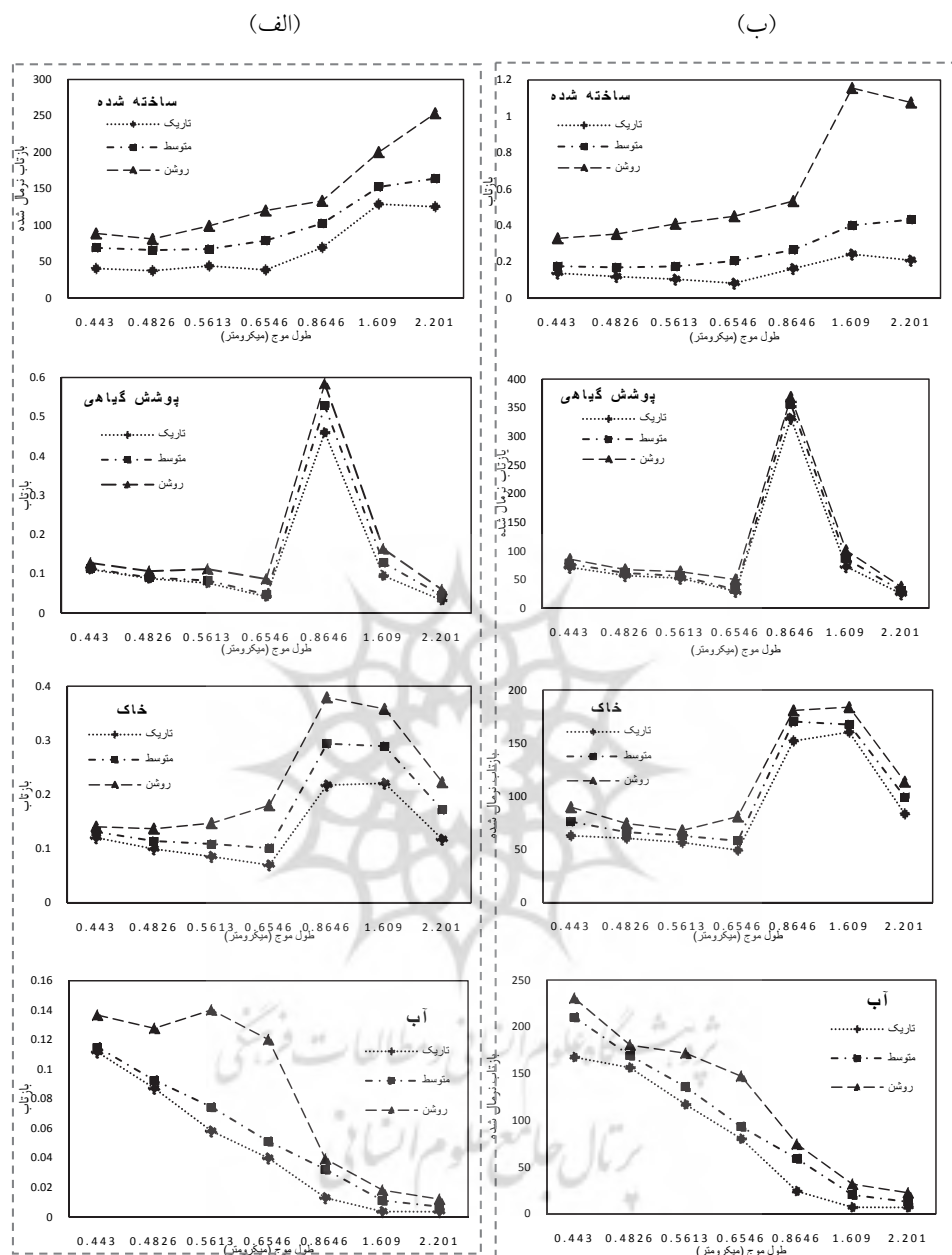
$$\text{net}_j = \sum_{i=1}^m W_{ij} O_i \quad \text{رابطه (۸)}$$

که در آن نشان‌دهنده وزن بین گره  $i$  و گره  $j$  می‌باشد و  $O_i$  خروجی گره  $i$  می‌باشد. خروجی یک گره مانند  $j$  از رابطه (۹) به دست می‌آید:

$$O_j = f(\text{net}_j) \quad \text{رابطه (۹)}$$

تابع  $f$  در رابطه (۹) معمولاً یک تابع غیرخطی سیگموئیدی است که بر روی مجموع وزن‌دار ورودی‌ها، قبل از این که سیگنال به لایه بعدی انتقال یابد، اعمال می‌شود. هنگامی که انتشار رو به جلو به پایان می‌رسد، فعالیت‌های گره‌های خروجی با فعالیت‌های مورد انتظار آنها مقایسه می‌شود. هر گره در لایه خروجی با یک کلاس متناظر است.

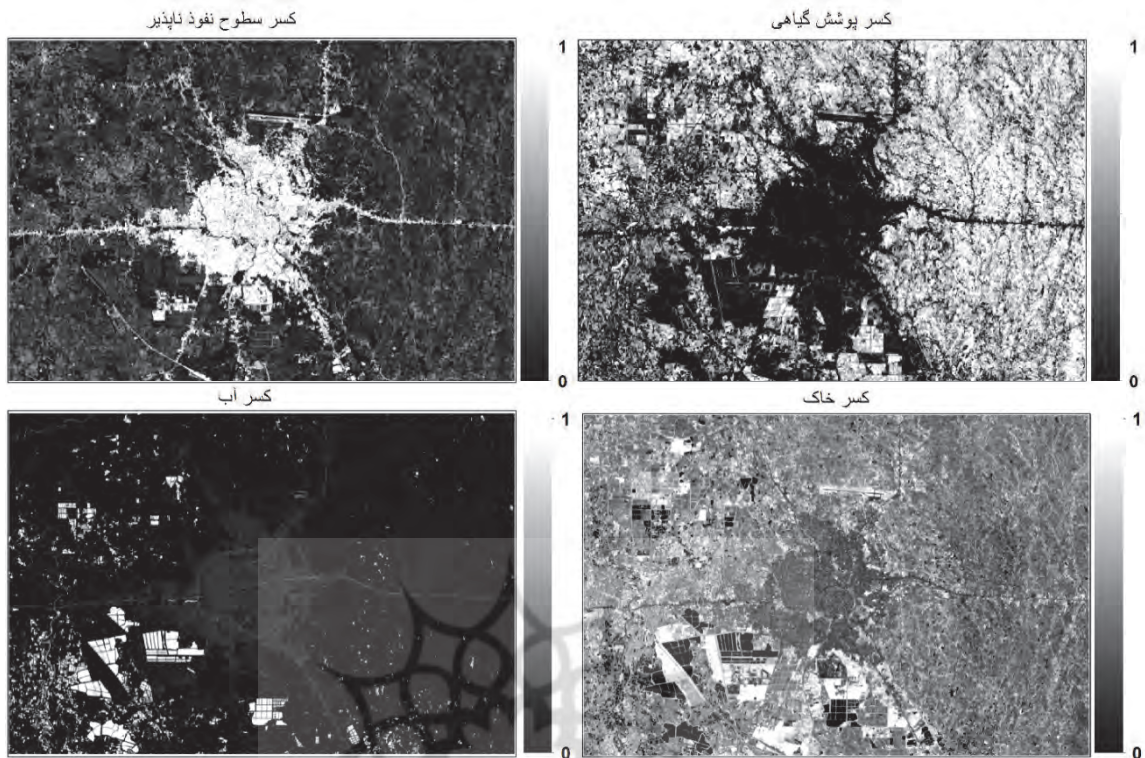
در این تحقیق از یک پرسپترون چند لایه با الگوریتم یادگیری پس انتشار (BP) و لایه‌های ورودی؛ ارتفاع، شیب، فاصله از مناطق ساخته شده، فاصله از جاده، فاصله از آبراهه و لایه حداکثر احتمال تغییر به اراضی ساخته شده استفاده شد. فرایند انجام پژوهش شامل دو مرحله است ابتدا استخراج ویژگی‌های سطح زمین با




نگاره ۳. مقایسه طیف عضوهای پایانی (*endmember*)، (الف) قبل از نرمال کردن تصاویر، (ب) بعد از نرمال کردن تصاویر

این روش طبقه‌بندی از دقت بالایی برخوردار است (جدول ۱) و برخلاف طبقه‌بندی بر پایه پیکسل، که خاک روشن را جزء طبقه ساخته شده قرار می‌دهد، به خوبی پوشش خاک را از اراضی ساخته شده جدا می‌کند. برای بررسی تغییرات کاربری زمین از روش مقایسه

خاص در پیکسل هستند، سرعت و دقت الگوریتم‌های طبقه‌بندی را بالا می‌برند. نگاره (۵) نقشه طبقه‌بندی منطقه در سال ۲۰۱۵ با استفاده از لایه‌های کسری پوشش به عنوان باندها و عضوهای پایانی به عنوان نمونه‌های آموزشی و با الگوریتم حداکثر احتمال می‌باشد.



نگاره ۴: کسرهای پوشش زمین بدست آمده از تصاویر بازتاب نرمال شده



اراضی آیش شالیزار و مرداب ساخته شده کشاورزی و باغات

نگاره ۵: نقشه طبقه‌بندی منطقه در سال ۲۰۱۵ با استفاده از لایه‌های کسری پوشش به عنوان باندها و عضوهای پایانی به عنوان نمونه‌های آموزشی و با الگوریتم حداکثر احتمال

پس از طبقه‌بندی استفاده شد. طبقه اراضی آیش با طبقه زمین‌های کشاورزی و باغات ادغام شد تا موجب اشتباه در محاسبات بعدی نشود. جدول (۲) نسبت مساحت طبقات زمین در سال‌های مختلف و تغییرات آن در دوره مورد مطالعه را نشان می‌دهد. میزان افزایش در مساحت کاربری اراضی ساخته شده برای دوره‌های ۲۰۰۲-۱۹۹۰، ۲۰۱۵-۲۰۰۲ و ۲۰۱۵-۱۹۹۰ به ترتیب ۱۵۸۰، ۳۵۱۳ هکتار بوده است.



فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (GIS) کاربرد تجزیه و تحلیل طیف مخلوط نرمال شده ... / ۷۳

مورد نظر ما در این تحقیق، تغییر کاربری ها به مناطق ساخته شده بود بنابراین سایر تغییرات نادیده شدند. لایه حداکثر احتمال تغییر بر اساس لایه تغییر کاربری ها به کاربری ساخته شده و لایه طبقه بندی سال پایه ساخته می شود. و حداکثر احتمال تبدیل یک طبقه زمین به طبقه مورد نظر محاسبه می شود. (۲) لایه فاصله از مناطق ساخته شده؛ برای ایجاد این لایه از تصویر طبقه بندی شده سال ۲۰۱۵ طبقه ساخته شده جدا شد و لایه فاصله اقلیدسی آن، تا محدوده مورد مطالعه محاسبه گردید. لایه فاصله از مناطق ساخته شده از آن جهت می تواند

جدول ۱: صحت طبقه بندی تصاویر سال های ۱۹۹۰، ۲۰۰۰ و ۲۰۱۵


صحت / سال	۱۹۹۰	۲۰۰۲	۲۰۱۵
صحت کلی	٪۹۹/۳۲۱	٪۹۹/۷۶۳	٪۹۹/۸۷۴
ضریب کاپا	۰/۹۸۴۳	۰/۹۸۵۲	۰/۹۸۶۸
صحت تولیدکننده	٪۹۹/۴۵	٪۹۹/۹۲	٪۹۹/۹۹
صحت کاربر	٪۹۹/۳۸	٪۹۹/۸۷	٪۹۹/۹۳

پیش بینی رشد شهری با شبکه عصبی

از پنج لایه پنهان برای آموزش شبکه و با شرایط توقف، ده هزار تکرار، میزان RMS ۰/۰۱ و میزان صحت

جدول ۲: مقدار تغییر کاربری اراضی در طول دوره مورد مطالعه از نظر هکتار و درصد در هر طبقه

سال طبقه	تغییرات مساحت کاربری اراضی			مساحت کاربری اراضی					
	۱۹۹۰-۲۰۱۵	۲۰۰۲-۲۰۱۵	۱۹۹۰-۲۰۰۲	۲۰۱۵		۲۰۰۲		۱۹۹۰	
	هکتار	هکتار	هکتار	درصد	هکتار	درصد	هکتار	درصد	هکتار
ساخته شده	۳۵۱۳	۱۵۸۰	۱۹۹۳	۱۶	۷۴۷۵	۱۲/۶	۵۸۹۵	۸/۵	۳۹۶۲
کشاورزی و باغات	- ۵۱۰۲	- ۲۷۱۷	- ۲۳۸۵	۷۸/۲	۳۶۳۵۱	۸۴	۳۹۰۶۸	۸۹/۲	۴۱۴۵۳
شالیزار و مرداب	۱۵۸۷	۱۱۳۴	۴۵۳	۵/۸	۲۶۸۶	۳/۴	۱۵۵۲	۲/۳	۱۰۹۹



نگاره ۵: لایه های ورودی شبکه عصبی

مهم باشد که هر اندازه سلولی به سلول ساخته شده نزدیکتر باشد احتمال تبدیل آن سلول به سلول ساخته شده به علت وجود زیرساخت ها و دسترسی ها، بالاتر

۱۰۰ درصد استفاده شد. لایه های مورد استفاده برای ورودی شبکه عصبی در این مطالعه شامل؛ (۱) لایه حداکثر احتمال تغییر به اراضی ساخته شده؛ تغییرات

جدول ۲: مشخصات کلی مدل ایجاد شده

۱. لایه‌های ورودی												
متغیر ۱	متغیر ۲	متغیر ۳	متغیر ۴	متغیر ۵	متغیر ۶							
فاصله از آبراهه	فاصله از مناطق ساخته شده	لایه حداکثر احتمال تغییر	لایه شیب	لایه ارتفاع	فاصله از جاده							
۲. پارامترها و عملکرد												
اندازه مهارت	میزان صحت	RMS آزمایشی	RMS آموزشی	تکرارها	RMS قابل پذیرش	ثابت	عامل موثقم	نرخ یادگیری پایانی	نمونه درخواستی در کلاس	نورونهای لایه خروجی	نورونهای لایه پنهان	نورونهای لایه ورودی
۰/۸۴۹۲	%۹۴/۴۶	۰/۱۰۳	۰/۰۹۲	۱۰۰۰۰	۰/۰۱	۱	۰/۵	۰/۰۰۵	۱۰۰۰	۲	۵	۶
۳. وادار کردن یک متغیر منفرد به ثابت بودن												
مدل	کل متغیرها	متغیر ۱ ثابت	متغیر ۲ ثابت	متغیر ۳ ثابت	متغیر ۴ ثابت	متغیر ۵ ثابت	متغیر ۶ ثابت					
صحت (%)	۹۴/۴۶	۹۴/۴۶	۹۴/۴۱	۶۰/۰۷	۹۴/۵۵	۹۴/۵۴	۹۴/۴۶					
اندازه مهارت	۰/۸۴۹۲	۰/۸۴۹۲	۰/۸۴۸۸	۰/۰۰۱۳	۰/۸۵۶	۰/۸۵۶	۰/۸۴۹۲					
رتبه تأثیرگذاری	غیر قابل اجرا	۴	۲	۱ بیشترین	۶ کمترین	۵	۳					
۴. وادار کردن تمام متغیرها به جز یکی به ثابت بودن												
مدل	کل متغیرها	کل متغیرها به غیر از متغیر ۱	کل متغیرها به غیر از متغیر ۲	کل متغیرها به غیر از متغیر ۳	کل متغیرها به غیر از متغیر ۴	کل متغیرها به غیر از متغیر ۵	کل متغیرها به غیر از متغیر ۶					
صحت (%)	۹۴/۴۶	۶۰/۰۷	۶۰/۰۷	۹۴/۴۶	۶۰/۰۷	۶۰/۰۷	۶۰/۰۷					
اندازه مهارت	۰/۸۴۹۲	۰/۰۰۱۳	۰/۰۰۱۳	۰/۸۰۲۵	۰/۰۰۱۳	۰/۰۰۱۳	۰/۰۰۱۳					

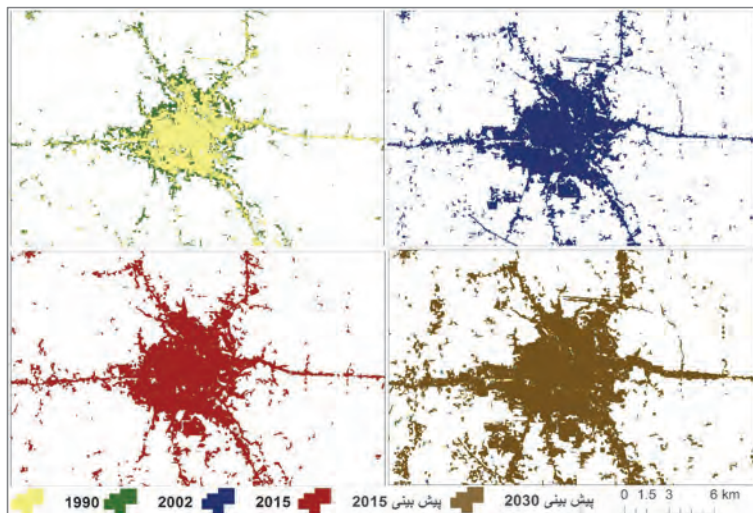
است. ۳) لایه فاصله از جاده؛ جاده‌ها یکی از مهم‌ترین عوامل گسترش ایجاد مناطق انسان ساز در مناطق شمالی ایران می‌باشند. لایه جاده‌های شهر رشت و محدوده آن از نقشه جاده‌های آزاد<sup>۱</sup> (OSM) تهیه شد و فاصله اقلیدسی آن در محدوده مورد مطالعه محاسبه شد. ۴) لایه‌های، ارتفاع، شیب و فاصله از آبراهه؛ برای لایه ارتفاع از مدل رقومی ارتفاع محصول سنجنده تشعشع سنج بازتاب و تابش گرمایی هوابرد پیشرفته<sup>۲</sup> (ASTER) و با توان تفکیک ۳۰ متر از سازمان زمین‌شناسی آمریکا<sup>۳</sup> (USGS)، تهیه گردید و لایه‌های شیب و آبراهه منطقه از آن بدست آمد. ارتفاع در شهر رشت بسیار پایین است و در قسمت شمالی منطقه مورد مطالعه ارتفاع حتی از سطح دریا پایین تر است. شیب منطقه نیز بسیار کم است و جهت آن به سمت شمال می‌باشد. نگاره (۵)، لایه‌های ورودی مورد استفاده در شبکه عصبی را نمایش می‌دهد.

مدل با میزان صحت ۹۴/۴۶٪ و اندازه مهارت ۰/۸۴۹۲ و RMS آزمایشی ۰/۱۰۳ و آموزشی ۰/۰۹۲ متوقف شد. مشخصات کلی مدل ایجاد شده در جدول (۳) آورده شده است.

1- Open Street Map

2- Advanced Space borne Thermal Emission and Reflection Radiometer

3- U. S. Geological Survey



نگاره ۷: مناطق ساخته شده سال‌های،  
 ۱۹۹۰، ۲۰۰۲ و ۲۰۱۵ با پیش‌بینی سال  
 ۲۰۱۵ و ۲۰۳۰

شهری با استفاده از تصاویر ماهواره‌ای، استخراج ویژگی‌های سطح شهری با دقت و صحت بالا می‌باشد. زیرا خطاهای ناشی استخراج عوارض سطح بروی نتایج کار اثر می‌گذارد. در این تحقیق از روش NSMA برای استخراج زیر پیکسل سطوح شهری استفاده شد. برای طبقه‌بندی تصاویر از لایه‌های کسری پوشش به عنوان لایه‌های ورودی و عضوهای پایانی به عنوان نمونه‌های آموزشی و با الگوریتم حداکثر احتمال استفاده شد و ضریب کاپای بالای ۰/۹۸ بدست آمد. این روش طبقه‌بندی توانست برخلاف طبقه‌بندی بر پایه پیکسل که خاک روشن را جزو طبقه ساخته شده قرار می‌دهد، به خوبی پوشش خاک را از اراضی ساخته شده جدا کند.

به منظور پیش‌بینی رشد شهری با شبکه عصبی در این تحقیق از مدل پرسپترون چند لایه (MLP) با الگوریتم یادگیری پس‌انتشار (BP) و لایه‌های ورودی؛ ارتفاع، شیب، فاصله از مناطق ساخته شده، فاصله از جاده، فاصله از آبراهه و لایه حداکثر احتمال تغییر به اراضی ساخته شده استفاده شد. برای اعتبارسنجی مدل از نقشه تغییرات سال ۱۹۹۰-۲۰۰۲ برای پیش‌بینی سال ۲۰۱۵ استفاده شد. نتایج مقایسه خروجی مدل با نقشه

#### اعتبارسنجی مدل

برای اعتبارسنجی مدل‌های پیش‌بینی کننده، باید مدل را با استفاده از داده‌های موجود در گذشته اجرا کرد و با داده‌های موجود در زمان حال مقایسه کرد تا صحت مدل در پیش‌بینی محاسبه گردد. برای این کار مدل شبکه عصبی با استفاده لایه تغییرات سال ۱۹۹۰-۲۰۰۲ و فاصله از مناطق ساخته شده و جاده سال ۲۰۰۲ ایجاد شد و سپس برای پیش‌بینی مناطق ساخته شده در سال ۲۰۱۵ اجرا شد. مقایسه نتیجه مدل با نقشه طبقه‌بندی سال ۲۰۱۵، با ضریب کاپای ۹۲ درصد، کاپای استاندارد ۸۹ درصد و کاپای طبقه‌ای (برای طبقه ساخته شده) ۹۳ درصد نتایج قابل قبولی را نشان داد. نگاره (۷) مناطق ساخته شده سال‌های، ۱۹۹۰، ۲۰۰۲ و ۲۰۱۵ با پیش‌بینی سال ۲۰۱۵ و ۲۰۳۰ را نشان می‌دهد. همانطور که از تصاویر مشخص است مدل استفاده شده در این تحقیق در پیش‌بینی رشد مرزهای شهر موفق عمل کرده است، اما در پیش‌بینی مناطق ساخته شده انفرادی اطراف شهر صحت کمتری دارد.

#### بحث و نتیجه‌گیری

مهم‌ترین بخش نظارت و پیش‌بینی در مناطق

vegetation and bare soil fractions from Landsat and MODIS data. *Remote Sensing of Environment*, 161, 12-26.

8- Hansen, M. C., DeFries, R. S., Townshend, J. R. G., Sohlberg, R., Dimiceli, C., & Carroll, M. (2002). Towards an operational MODIS continuous field of percent tree cover algorithm: examples using AVHRR and MODIS data. *Remote Sensing of Environment*, 83(1), 303-319.

9- Hsieh, W. W. (2009). Machine learning methods in the environmental sciences: neural networks and kernels. Cambridge university press.

10- Ji, M., & Jensen, J. R. (1999). Effectiveness of subpixel analysis in detecting and quantifying urban imperviousness from Landsat Thematic Mapper imagery. *Geocarto International*, 14(4), 33-41.

11- Karul, C., & Soyupak, S. (2003). A comparison between neural network based and multiple regression models for chlorophyll-a estimation. In *Ecological Informatics* (pp. 249-263). Springer Berlin Heidelberg.

12- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).

13- Myint, S. W., & Okin, G. S. (2009). Modelling land cover types using multiple endmember spectral mixture analysis in a desert city. *International Journal of Remote Sensing*, 30(9), 2237-2257.

14- Pijanowski, B. C., Brown, D. G., Shellito, B. A., & Manik, G. A. (2002). Using neural networks and GIS to forecast land use changes: a land transformation model. *Computers, environment and urban systems*, 26(6), 553-575.

15- Pijanowski, B. C., Tayyebi, A., Doucette, J., Pekin, B. K., Braun, D., & Plourde, J. (2014). A big data urban growth simulation at a national scale: Configuring the GIS and neural network based Land Transformation Model to run in a High Performance Computing (HPC) environment. *Environmental Modelling & Software*, 51, 250-268.

طبقه بندی سال ۲۰۱۵، ضریب کاپای ۹۲ درصد، کاپای استاندارد ۸۹ درصد و کاپای طبقه‌ای (برای طبقه ساخته شده) ۹۳ درصد، را نشان داد. مدل استفاده شده در این تحقیق در پیش‌بینی رشد مرزهای شهر موفق عمل کرده است، اما در پیش‌بینی مناطق ساخته شده انفرادی اطراف شهر صحت کمتری دارد.

#### منابع و مأخذ

- 1- Adams, J. B., Smith, M. O., & Johnson, P. E. (1986). Spectral mixture modeling: a new analysis of rock and soil types at the Viking Lander 1 site. *Journal of Geophysical Research: Solid Earth* (1978–2012), 91(B8), 8098-8112.
- 2- Aisa, B., Mingus, B., O'Reilly, R.C., 2008. The emergent neural modelling system. *Neural Netw.* 21, 1045–1212.
- 3- Chan, J. C. W., Chan, K. P., & Yeh, A. G. O. (2001). Detecting the nature of change in an urban environment: A comparison of machine learning algorithms. *Photogrammetric Engineering and Remote Sensing*, 67(2), 213-226.
- 4- Ciresan, D., Meier, U., & Schmidhuber, J. (2012, June). Multi-column deep neural networks for image classification. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on* (pp. 3642-3649). IEEE.
- 5- Franke, J., Roberts, D. A., Halligan, K., & Menz, G. (2009). Hierarchical multiple endmember spectral mixture analysis (MESMA) of hyperspectral imagery for urban environments. *Remote Sensing of Environment*, 113(8), 1712-1723.
- 6- Ghosh, S., Roy, M., & Ghosh, A. (2014). Semi-supervised change detection using modified self-organizing feature map neural network. *Applied Soft Computing*, 15, 1-20.
- 7- Guerschman, J. P., Scarth, P. F., McVicar, T. R., Renzullo, L. J., Malthus, T. J., Stewart, J. B., ... & Trevithick, R. (2015). Assessing the effects of site heterogeneity and soil properties when unmixing photosynthetic vegetation, non-photosynthetic



Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, 8(3), 1339-1352.

26- Weng, Q., & Lu, D. (2009). Landscape as a continuum: an examination of the urban landscape structures and dynamics of Indianapolis City, 1991-2000, by using satellite images. *International Journal of Remote Sensing*, 30(10), 2547-2577.

27- Wu, C. (2009). Quantifying high resolution impervious surfaces using spectral mixture analysis. *International Journal of Remote Sensing*, 30(11), 2915-2932.

28- Wu, C. (2004). Normalized spectral mixture analysis for monitoring urban composition using ETM+ imagery. *Remote Sensing of Environment*, 93(4), 480-492.

29- Wu, C., & Murray, A. T. (2003). Estimating impervious surface distribution by spectral mixture analysis. *Remote sensing of Environment*, 84(4), 493-505.

16- Powell, R. L., Roberts, D. A., Dennison, P. E., & Hess, L. L. (2007). Sub-pixel mapping of urban land cover using multiple endmember spectral mixture analysis: Manaus, Brazil. *Remote Sensing of Environment*, 106(2), 253-267.

17- Ridd, M. K. (1995). Exploring a VIS (vegetation-impervious surface-soil) model for urban ecosystem analysis through remote sensing: comparative anatomy for cities†. *International journal of remote sensing*, 16(12), 2165-2185.

18- Roberts, D. A., Batista, G., Pereira, J., Waller, E., & Nelson, B. (1999). Change identification using multitemporal spectral mixture analysis: Applications in eastern Amazonia.

19- Small, C. (2005). A global analysis of urban reflectance. *International Journal of Remote Sensing*, 26(4), 661-681.2

20- Smith, M. O., Ustin, S. L., Adams, J. B., & Gillespie, A. R. (1990). Vegetation in deserts: I. A regional measure of abundance from multispectral images. *Remote sensing of Environment*, 31(1), 1-26.

21- Song, C. (2005). Spectral mixture analysis for subpixel vegetation fractions in the urban environment: How to incorporate endmember variability?. *Remote Sensing of Environment*, 95(2), 248-263.

22- Tayyebi, A., Pijanowski, B. C., & Tayyebi, A. H. (2011). An urban growth boundary model using neural networks, GIS and radial parameterization: An application to Tehran, Iran. *Landscape and Urban Planning*, 100(1), 35-44.

23- Triantakostas, D., & Stathakis, D. (2015). Urban Growth Prediction in Athens, Greece, Using Artificial Neural Networks. *Int. J. Civil Struct. Constr. Archit. Eng*, 9, 193-197.

24- Yang, X. (Ed.). (2011). *Urban remote sensing: Monitoring, synthesis and modeling in the urban environment*. John Wiley & Sons.

25- Wang, Q., Shi, W., Atkinson, P. M., & Li, Z. (2015). Land Cover Change Detection at Subpixel Resolution With a Hopfield Neural Network.



پرویشگاه علوم انسانی و مطالعات فرهنگی  
پرتال جامع علوم انسانی