



آشکارسازی تغییرات مناطق شهری مبتنی بر شبکه‌های عصبی، ویژگی‌های مکانی و الگوریتم ژنتیک با استفاده از تصاویر ماهواره‌ای بزرگ مقیاس

فرامرز سرمدی^{۱*}، حمید عبادی^۲، علی محمدزاده^۳

۱. دانشجوی کارشناسی ارشد سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی
۲. دانشیار دانشکده مهندسی نقشه‌برداری، پژوهشکده سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی
۳. استادیار دانشکده مهندسی نقشه‌برداری، پژوهشکده سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ پذیرش مقاله: ۱۳۹۴/۱۰/۱۴

تاریخ دریافت مقاله: ۱۳۹۴/۵/۲۴

چکیده

آشکارسازی تغییرات پوشش اراضی برای پایش رشد شهرها و برنامه‌ریزی مسئولانه در مورد آنها امری ضروری است. سنجش از دور فناوری قدرتمندی است که می‌توان از آن در آشکارسازی تغییرات اراضی استفاده کرد. یکی از چالش‌های موجود در این زمینه توسعه روش‌های کارآمد به منظور آشکارسازی تغییرات با سطح خودکار سازی بالاست که بتواند اطلاعاتی صحیحی در مورد موقعیت جغرافیایی و ماهیت این تغییرات ارائه کند. در پژوهش حاضر با استفاده از دو تصویر GeoEye منطقه ۱۷ شهر تهران مربوط به سال‌های ۲۰۰۴ و ۲۰۱۰ از ویژگی‌های مکانی متن تصویر، شبکه‌های عصبی و الگوریتم ژنتیک برای آشکارسازی تغییرات استفاده شد. شش حالت مختلف، هریک با دو رویکرد طبقه‌بندی مستقیم چندزمانی و مقایسه پس از طبقه‌بندی، از دیدگاه صحت آشکارسازی و زمان اجرای الگوریتم مورد مقایسه قرار گرفتند. بررسی‌های انجام شده نشان دادند که رویکرد طبقه‌بندی مستقیم چندزمانی در هر شش حالت نتایج بهتری ارائه کرده است. همچنین در بین شش حالت بررسی شده، عملکرد حالت ششم (روش پیشنهادی این تحقیق) از نظر صحت طبقه‌بندی بهتر است. در حالت ششم پس از انتخاب بهینه ویژگی‌ها، طبقه‌بندی مبتنی بر شبکه‌های عصبی با تعیین معماری شبکه و با چندین بار اجرا صورت می‌گیرد. هرچند زمان اجرای این روش در مقایسه با دیگر حالت‌های بررسی شده بیشتر است، اما در صورتی که صحت طبقه‌بندی به زمان ارجحیت داشته باشد این روش کاملاً توصیه می‌شود.

کلیدواژه‌ها: آشکارسازی تغییرات، گسترش شهر، ویژگی‌های مکانی، شبکه‌های عصبی، الگوریتم ژنتیک.

* نویسنده مکاتبه کننده: تهران پارس، بزرگراه رسالت، خیابان ۱۵۸ غربی، پلاک ۱۳۴، واحد ۸

۱- مقدمه

تغییرات زیست‌محیطی جهان به معضل بزرگ ملی و بین‌المللی در حوزه سیاست‌گذاری تبدیل شده است. این تغییرات ممکن است تأثیرات نامطلوبی در اکوسیستم و منابع داشته باشند. تعیین تغییرات پوشش و کاربری اراضی در دوره‌های زمانی مختلف برای بررسی رشد شهرها و برنامه‌ریزی مسئولانه و آگاهانه در مورد آنها ضروری است (Bruzzone & Serpico, 1997).

حجم فراوانی از اطلاعات درباره طبیعت زمین به‌وسیله داده‌های سنجش از دور جمع‌آوری می‌شود. قدرت تفکیک فضایی و طیفی تصاویر سنجش از دوری پیوسته بهبود یافته است و امروزه حجم زیادی از این داده‌ها در دسترس قرار دارند. سنجش از دور را می‌توان به‌عنوان فناوری‌ای قدرتمند در آشکارسازی تغییرات^۱ پوشش و کاربری اراضی به‌کار گرفت. داده‌های چندزمانی سنجش از دور برای تعیین تغییرات کاربری و پوشش اراضی در مناطق شهری مناسباند (LONG, 1999). معمولاً آشکارسازی تغییرات شامل دو یا چند تصویر سنجش از دور هم‌مرجع از یک منطقه مشخص و در زمان‌های مختلف به‌همراه داده‌های واقعیت زمینی طیفی یا طیفی زمانی است.

۱-۱- ضرورت انجام تحقیق

در مطالعاتی که پیش از این صورت گرفته و سوابق آن در بخش ۰ آورده شده تا کنون از ویژگی‌های مکانی بافت به‌منظور آشکارسازی تغییرات مبتنی بر شبکه‌های عصبی استفاده نشده است. در پژوهش حاضر قابلیت بهبود صحت آشکارسازی با استفاده از این ویژگی‌ها در شبکه عصبی بررسی خواهد شد.

استفاده از ویژگی‌های مکانی در مناطقی که کلاس‌های پوشش اراضی همگون نیستند یا کلاس‌های مختلف آنها از دیدگاه طیفی شباهت بالایی دارند، می‌تواند سبب بهبود نتایج طبقه‌بندی شود. به‌طور مثال در مناطق شهری ساختمان‌ها معمولاً از دیدگاه طیفی همگون نیستند و با کلاس راه تشابه طیفی زیادی

دارند. از این رو انتظار می‌رود استفاده از ویژگی‌های طیفی همانند بافت، قابلیت تشخیص و تمایز الگوریتم طبقه‌بندی مورد استفاده را دست‌کم در برخی کلاس‌ها افزایش دهد (Kabir et al., 2010).

مطالعاتی که آشکارسازی تغییرات را بررسی کرده‌اند، برخی از رویکرد طبقه‌بندی مستقیم چندزمانی^۲ و برخی از رویکرد مقایسه پس از طبقه‌بندی^۳ استفاده کرده‌اند. پیش از این، پژوهشی که این دو رویکرد طبقه‌بندی را از نظر صحت ارزیابی و مقایسه کند، انجام نشده است. به همین دلیل در پژوهش حاضر این مقایسه در شش حالت مختلف صورت گرفته است.

در آشکارسازی تغییرات مبتنی بر شبکه‌های عصبی دو چالش عمده وجود دارد؛ نخست حساسیت شبکه‌های عصبی به‌تعداد نرون‌های لایه میانی و دوم ناپایداری شبکه عصبی نسبت به وزن‌دهی اولیه و وابستگی نتایج به آن. در پژوهش حاضر به این دو موضوع نیز پرداخته شده و کوشش شده است با روش سعی و خطا و ترسیم نمودار این مشکل رفع شود. در بخش معماری شبکه، وزن‌دهی اولیه و ارزیابی نتایج به این موارد اشاره شده است.

۱-۲- سوابق تحقیق

در این بخش به‌طور اجمالی مطالعات پیشین که به موضوع آشکارسازی تغییرات با استفاده از شبکه‌های عصبی یا به‌صورت مقایسه‌ای از روش‌های مختلف پرداخته‌اند، بررسی می‌شوند.

لانگ^۴ (۱۹۹۹) به بررسی آشکارسازی تغییرات در منطقه شهری با استفاده از تصاویر لندست و با رویکرد طبقه‌بندی مستقیم با استفاده از شبکه‌های عصبی پرداخت. در پژوهش وی به ویژگی‌های طیفی اکتفا شد

1. Change Detection
2. Direct Multi-date Classification (DMC)
3. Post Classification Comparison (PCC)
4. Long

تفکیک خطی به دست می‌دهند. به نظر می‌رسد طبقه‌بندی مستقیم چندزمانی عملکرد بهتری از روش مقایسه پس از طبقه‌بندی دارد و علت کمتر استفاده شدن این روش در مقالات پیشین مشکل تهیه داده‌های آموزشی و ارزیابی برای طبقه‌بندی مستقیم چندزمانی است. البته در مقاله پو و همکاران این برتری مورد ارزیابی قرار نگرفته است.

در تحقیقی که نیگو^۷ و همکاران (۲۰۱۲) انجام دادند، مقایسه‌ای بین روش‌های آشکارسازی تغییرات در تصاویر سنجنش از دور ارائه شد و چند روش آشکارسازی تغییرات نظارت‌شونده شبکه‌های عصبی (پرسپترون چندلایه، RBF^۸ و SOM^۹) در قیاس با روش‌های نظارت‌شونده آماری (حداکثر شباهت و نزدیک‌ترین همسایه) بررسی و ارزیابی شدند. ویژگی‌های استفاده‌شده در پژوهش مذکور، شامل ویژگی‌های دوزمانی پیکسل‌های مرتبط دو تصویر است. برخلاف انتظار در این مطالعه بهترین نتایج از روش بیشترین شباهت به دست آمد.

۱-۳- هدف تحقیق

در بیشتر پژوهش‌های پیشین بر مزیت شبکه‌های عصبی بر آشکارسازی تغییرات تأکید شده و پیش از این استفاده از ویژگی‌های مکانی بهینه در آشکارسازی تغییرات مبتنی بر شبکه‌های عصبی بررسی نشده است. هدف پژوهش حاضر ارائه روشی بر اساس ویژگی‌های مکانی متن‌تصویر، شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک برای بهبود صحت آشکارسازی تغییرات است. برای فراهم‌آوردن امکان ارزیابی روش پیشنهادی

و ویژگی‌های مکانی به کار گرفته نشدند. لانگ در خصوص تعیین معماری شبکه نیز روشی ارائه نکرد. نتایج تحقیق وی نشان از افزایش ۹ درصدی صحت طبقه‌بندی در مقایسه با روش طبقه‌بندی بیش‌ترین شباهت دارند.

پاسیفیک^۱ و همکاران (۲۰۰۷) در مطالعه‌ای شبکه‌های عصبی را به منظور آشکارسازی تغییرات با رویکرد طبقه‌بندی مستقیم به کار گرفتند و روشی موسوم به NAHIRI^۲ را شرح و بسط دادند. ماسک تغییرات با استفاده از شبکه عصبی و با سه ویژگی حاصل از نسبت دو تصویر تولید شد و روی نقشه تغییرات حاصل از رویکرد مقایسه پس از طبقه‌بندی مبتنی بر شبکه عصبی اعمال گردید و از این طریق تغییرات غیرواقعی حذف شدند. نتایج این روش در مقایسه با روش مقایسه پس از طبقه‌بندی، ۲۶ درصد بهبود نشان می‌دهند، که به نظر می‌رسد به دلیل حذف تغییرات غیرواقعی ناشی از روش مقایسه پس از طبقه‌بندی باشد. در مطالعه مذکور صرفاً از اطلاعات طیفی پیکسل پایه استفاده شده و اطلاعات همسایگی و بافت در نظر گرفته نشده است. رویکرد طبقه‌بندی مستقیم چندزمانی نیز برای تولید نقشه تغییرات مورد بررسی قرار نگرفته است.

چینی^۳ و همکاران (۲۰۰۸)، روش NAHIRI را با استفاده از طبقه‌بندی‌های بیشترین شباهت و شبکه عصبی به کار گرفتند. نتایج مطالعه آنها افزایش صحت ۷ درصدی را در مورد الگوریتم بیش‌ترین شباهت و ۱۴ درصدی در مورد شبکه عصبی نشان می‌دهد. در پژوهش مذکور نیز اطلاعات همسایگی و رویکرد طبقه‌بندی مستقیم چندزمانی مورد بررسی قرار نگرفت. در تحقیق پو^۴ و همکاران (۲۰۰۸) دو روش طبقه‌بندی شبکه عصبی مصنوعی و تحلیل تفکیک خطی، روی ۱۲ مؤلفه اول تبدیل PCA^۵ دو تصویر فراطیفی و با رویکرد طبقه‌بندی مستقیم چندزمانی مقایسه شد. نتیجه مطالعه مذکور نشان داد که روش طبقه‌بندی ANN^۶ نتایج بهتری در مقایسه با تحلیل

1. Pacifici
2. Neural Architecture for High-Resolution Imagery
3. Chini
4. Pu
5. Principal Component Analysis
6. Artificial Neural Networks
7. Neaoge
8. Radial Based Function
9. Self-Organizing Map

اولیه متفاوت به منظور دستیابی به بالاترین صحت ممکن است. حالت چهارم تعیین ویژگی‌های بهینه با استفاده از الگوریتم ژنتیک با تابع شایستگی ضریب کاپای طبقه‌بندی است. حالت پنجم و ششم به ترتیب مشابه حالت دوم و سوم است، با این تفاوت که به جای باندهای اصلی تصویر از ویژگی‌های بهینه انتخاب شده از حالت چهارم به عنوان ورودی شبکه عصبی استفاده می‌شود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

مجموعه داده پژوهش حاضر شامل تصاویر ماهواره GeoEye سال‌های ۲۰۰۴ و ۲۰۱۰ از منطقه ۱۷ تهران با ابعاد ۴۰۰×۸۰۰ پیکسل است. این تصاویر شامل سه باند طیفی مرئی است. دو تصویر با دقت کمتر از نیم پیکسل هم‌مرجع شدند (شکل).

از نظر دقت و زمان اجرا، شش حالت مختلف برای آشکارسازی تغییرات هر یک با دو رویکرد طبقه‌بندی مستقیم دوزمانی و مقایسه پس از طبقه‌بندی طراحی و پیاده‌سازی شد و نتایج آنها با یکدیگر مقایسه گردید. در بخش دوم، روش پیشنهادی به منظور آشکارسازی تغییرات تشریح می‌شود. در این بخش مقایسه و ارزیابی شش حالت مختلف انجام می‌شود تا بتوان روش اصلی این مقاله (حالت ششم) را از جنبه‌های مختلف ارزیابی کرد. حالت نخست روش طبقه‌بندی حداکثر شباهت با باندهای اصلی تصویر است، چراکه روش بیشترین شباهت در بسیاری از تحقیقات به عنوان روش سنتی و معیار مقایسه با روش اصلی تحقیق مورد استفاده قرار می‌گیرد. حالت دوم طبقه‌بندی شبکه‌های عصبی با باندهای اصلی تصویر به منظور تعیین تعداد نرون‌های لایه میانی است. حالت سوم چند بار اجرای شبکه حالت دوم با وزن‌دهی‌های



شکل ۱. تصاویر GeoEye سال‌های ۲۰۰۴ و ۲۰۱۰

جدول ۱. کلاس‌های مورد استفاده در آشکارسازی تغییرات

شماره کلاس	کلاس تغییر	تعداد نمونه‌های آموزش	تعداد نمونه‌های ارزیابی
۱	ساختمان به خاک برهنه	۲۰۰	۲۰۰
۲	ساختمان به پوشش گیاهی	۲۰۰	۲۰۰
۳	راه به خاک برهنه	۲۰۰	۲۰۰
۴	راه به پوشش گیاهی	۲۰۰	۲۰۰
۵	ساختمان به ساختمان	۲۰۰	۲۰۰
۶	خاک برهنه به خاک برهنه	۲۰۰	۲۰۰
۷	راه به راه	۲۰۰	۲۰۰
۸	پوشش گیاهی به پوشش گیاهی	۲۰۰	۲۰۰
۹	خاک برهنه به پوشش گیاهی	۲۰۰	۲۰۰
۱۰	پوشش گیاهی به خاک برهنه	۲۰۰	۲۰۰

انجام می‌شود. برای استفاده مناسب از این تکنیک باید دو مجموعه جداگانه از داده‌های آموزشی و ارزیابی از کلاس‌های تغییر استخراج شود (Bruzzone & Serpico, 1997).

با توجه به اینکه تا کنون بررسی جامعی به‌منظور مقایسه دو رویکرد DMC و PCC انجام نشده است، در کلیه حالت‌های شش‌گانه این تحقیق این دو رویکرد پیاده‌سازی و مقایسه شدند و نتایج حاصل از آن در بخش سوم آمده است.

۲-۳- طبقه‌بندی با شبکه‌های عصبی

تحقیقات در زمینه استفاده از شبکه‌های عصبی در طبقه‌بندی تصاویر سنجنش از دور در حدود دو دهه پیش آغاز شدند. پژوهشگران دریافته‌اند که این روش برای طبقه‌بندی تصاویر سنجنش از دور کارایی بالایی دارد (Heermann & Khazenie, 1992). در بسیاری از کاربردهای سنجنش از دور، طبقه‌بندی شبکه عصبی مزیت خود را به روش‌های سنتی با افزایش صحت کلی

در جدول ۱، ده کلاس که مرتبط با تغییرات بین دو تصویر است به‌همراه تعداد نمونه‌های آموزشی هر کلاس آمده است. کلاس‌های ۵، ۶، ۷ و ۸ کلاس‌های غیرتغییر و بقیه کلاس‌ها بیانگر کلاس‌های تغییر هستند.

۲-۲- قیاس رویکردهای آشکارسازی

دو رویکرد عمده در خصوص آشکارسازی تغییرات در سنجنش از دور وجود دارد: مقایسه پس از طبقه‌بندی و طبقه‌بندی مستقیم چندزمانی. روش مقایسه پس از طبقه‌بندی، نقشه‌های حاصل از طبقه‌بندی را که در دو زمان مختلف دریافت شده‌اند در یک روش مقایسه‌ای، پیکسل به پیکسل مقایسه می‌کند تا تغییرات را مشخص کند. از نظر کاپین و باور^۱ (۱۹۹۶) عملکرد این روش به شدت به دقت طبقه‌بندی‌های مجزا وابسته است، زیرا این روش به وابستگی آماری بین دو تصویر توجه نمی‌کند. در مقابل، طبقه‌بندی مستقیم دوزمانی از آنالیز مجموعه داده پشته‌سازی شده^۲ برای استخراج تغییرات استفاده می‌کند. هر ترکیب تغییر بین دو زمان به صورت یک کلاس خروجی تغییر نمایش داده شده است و فرایند آشکارسازی تغییرات به صورت طبقه‌بندی واحد

1. Coppin & Bauer
2. Stacked Images

۲-۴- استخراج و انتخاب ویژگی

روش‌های طیفی به دلیل در نظر نگرفتن اطلاعات همسایگی پیکسل‌ها، برای تصاویر بزرگ مقیاس و مناطق ناهمگون چندان مناسب نیستند (Kabir et al., 2010). طبقه‌بندی با ویژگی‌های مکانی مناسب در کلاس‌های با پاسخ‌های طیفی ترکیبی افزایش صحت را به دنبال دارد؛ مانند مناطق گیاهی کم تراکم و مناطق شهری (Zhang, 1999). بافت از خصوصیات بارز اشیای تصویر از لحاظ بصری و از لحاظ پردازش تصویر است. این ویژگی‌ها به توزیع مکانی مقادیر درجه خاکستری بستگی دارد. آنالیز بافت، امکانات جالبی برای تشخیص ناهمگونی ساختاری کلاس‌ها به دست می‌دهد و شامل اطلاعاتی راجع به کنتراست، همگونی، چین خوردگی، منظم بودن و نظایر اینهاست. ماتریس هم‌اتفاق درجات خاکستری^۳ (Haralick et al., 1973) که در این مطالعه استفاده شده است، یکی از روش‌های متداول استخراج ویژگی‌های بافت از تصاویر است. برای استخراج ویژگی‌های مکانی از متن تصویر در این مطالعه از نرم‌افزار ENVI استفاده شده است.

در پژوهش حاضر هشت ویژگی بافت بررسی شده است. شکل ۱ این ویژگی‌های مکانی را نشان می‌دهد. پس از استخراج ویژگی‌های مکانی از تصویر چندطیفی بایستی انتخاب ویژگی‌ها به گونه‌ای صورت گیرد که صحت طبقه‌بندی افزایش یابد. بدیهی است که انتخاب ویژگی به روش آزمون و خطا و تفسیر بصری ویژگی‌ها، با خطا و اشتباه همراه است و کاملاً به تجربه کاربر بستگی دارد. استفاده از همه ویژگی‌های مکانی به دلیل وابستگی آماری این ویژگی‌ها صحت طبقه‌بندی را کاهش می‌دهد. به همین دلیل استفاده از روشی که بتواند با حداقل دخالت کاربر و با صحت بالا ویژگی‌های بهینه مکانی را انتخاب کند، مفید به نظر می‌رسد.

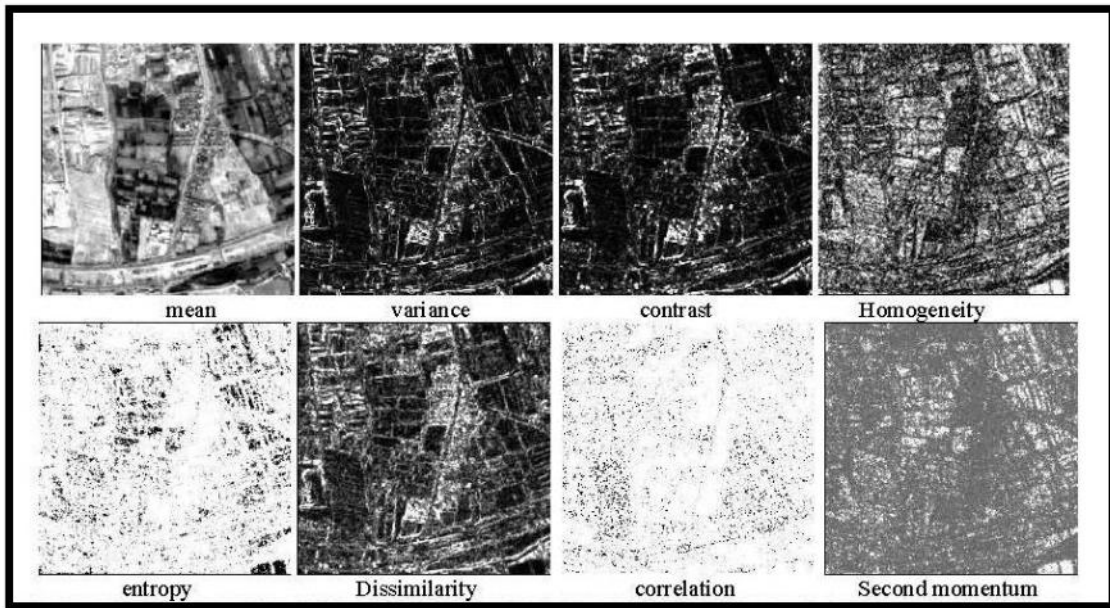
طبقه‌بندی نشان داده است (Paola & Schowengerdt, 1995; Dai & Khorram, 1995). علاوه بر کاربردهای طبقه‌بندی پوشش و کاربری اراضی، شبکه‌های عصبی مصنوعی در آشکارسازی تغییرات سنجش از دور نیز به کار می‌آیند (Chen et al., 1995). شبکه‌های عصبی مصنوعی در آشکارسازی تغییرات به دلیل پیچیدگی داده‌ها که دارای مؤلفه‌های زیادی هستند و گاهی حتی چندمنبعی هستند، مناسب به نظر می‌رسند. یکی از مزایای مهم شبکه‌های عصبی در مقایسه با روش‌های آماری سنتی این است که این شبکه‌ها به توزیع آماری داده‌ها وابسته نیستند (Benediktsson et al., 1990). برای آشنایی با ساختار شبکه‌های عصبی و نحوه آموزش و فراخوانی در این شبکه‌ها می‌توان به مطالعه روملهارت^۱ و همکاران (۱۹۸۶) مراجعه کرد.

توانایی تشخیص شبکه بستگی زیادی به پارامترهای آن دارد. نرخ آموزش و ضریب اینرسی نقش مهمی در موفقیت فرایند آموزش دارند و باید از سوی کاربر معرفی شوند (بستگی به مسئله دارد). در الگوریتم شبکه عصبی اغلب داده‌های ورودی در محدوده صفر و یک وارد می‌شوند، این کار توان همگرایی شبکه را به نتایج واقعی افزایش می‌دهد (Paola & Schowengerdt, 1995). بنابراین، مهم است که ارزش هر پیکسل را در این محدوده نرمال کرد و مقادیر نرمالیزه شده به گره‌های ورودی معرفی شوند. توقف بهنگام فرایند آموزش، مسئله مهمی است. اگر شبکه بیش از آنچه لازم است آموزش ببیند، نمونه‌های آموزشی بیش از حد به وسیله شبکه آموخته می‌شوند و توانایی تشخیص پایین می‌آید. بنابراین، شرط خاتمه باید به درستی به منظور خودداری از آموزش بیش از حد^۲ تعیین شود و بهترین شرایط خاتمه را پیدا کند. اگر نرخ آموزش به خوبی تعدیل شده باشد، می‌تواند سرعت آموزش را افزایش دهد.

1. Rumelhart

2. Over Training

3. Gray Level Co-occurrence Matrix (GLCM)



شکل ۱. ویژگی‌های بافت (واریانس، میانگین، کنتراست، هموژنیته، آنروپی، عدم شباهت، همبستگی و گشتاور دوم) استفاده شده در این تحقیق که از نرم‌افزار ENVI استخراج شده‌اند.

حاضر این است که نتایج حاصل از این دو روش (تابع شایستگی بیش‌ترین شباهت و تابع شایستگی شبکه‌های عصبی) از دیدگاه صحت طبقه‌بندی تفاوت چندانی با یکدیگر ندارند. برای اثبات این فرض، مقایسه‌ای بین این دو روش با استفاده از مجموعه داده‌ای بسیار کوچک‌تر از مجموعه داده اصلی تحقیق انجام شد. در این حالت برای هر کلاس از ۵۰ نمونه استفاده شد. علاوه بر آن فقط باندهای اصلی تصویر در کنار ویژگی‌های با ابعاد پنجره ۳ وارد فرایند بهینه‌سازی با استفاده از الگوریتم ژنتیک شدند. نتایج نشان دادند که این دو روش در آشکارسازی تفاوت چندانی با یکدیگر ندارند و نتایج مشابهی به دست می‌دهند، به طوری که ضریب کاپای طبقه‌بندی با شبکه عصبی مبتنی بر ویژگی‌های بهینه‌شده بیش‌ترین شباهت برابر ۷۳ و ضریب کاپای طبقه‌بندی با شبکه عصبی مبتنی بر ویژگی‌های بهینه‌شده شبکه عصبی برابر ۷۲ است؛ اما از نظر زمان اجرا روش شبکه عصبی حدود پنج برابر زمان برتر است.

در پژوهش حاضر از الگوریتم ژنتیک برای انتخاب بهینه ویژگی‌ها استفاده شده است. ضریب کاپای طبقه‌بندی حداکثر شباهت به عنوان تابع شایستگی مورد استفاده قرار گرفته است. انتخاب ویژگی‌های مکانی مبتنی بر طبقه‌بندی شبکه عصبی به دلیل زمان‌بر بودن محاسبه تابع شایستگی شبکه عصبی برای ژنتیک و حساسیت تابع شایستگی به معماری و وزندهی اولیه شبکه عصبی مشکل‌ساز است. به همین دلیل در طبقه‌بندی شبکه عصبی که در این تحقیق به کار رفته است، از ویژگی‌های انتخابی الگوریتم حداکثر شباهت استفاده می‌شود (حالت چهارم بخش ۲-۷).

ممکن است پرسیده شود درحالی که روش طبقه‌بندی اصلی در این تحقیق مبتنی بر شبکه‌های عصبی است، چرا برای بهینه‌سازی انتخاب ویژگی‌های مکانی از تابع شایستگی ضریب کاپای طبقه‌بندی حداکثر شباهت استفاده شده و پس از ویژگی‌های بهینه‌شده انتخاب شده به عنوان ورودی به شبکه عصبی معرفی شده است؟ در پاسخ باید گفت، فرض تحقیق

جدول ۲. پارامترهای الگوریتم ژنتیک به کار گرفته شده

مقدار	پارامتر	ردیف
باینری	کدگذاری جمعیت‌ها	۱
۲۰	جمعیت هر نسل	۲
۰/۱	نرخ جهش	۳
تورنمنت ^۱	انتخاب والدین	۴
دونقطه‌ای ^۲	تقاطع ^۲	۵
ضریب کاپا	تابع شایستگی	۶
۰/۰۱	میانگین اختلافات تابع شایستگی نسبت به نسل قبل (معیار توقف)	۷

زیاد به معنای تخمین بیش از حد پیچیدگی‌های مسئله است و سبب افت قدرت پیش‌بینی شبکه عصبی خواهد شد (Liu et al., 2007). تعداد ورودی‌ها و خروجی‌های مورد نیاز و ساختار اولین و آخرین لایه‌های شبکه عصبی پس از تعیین نوع ورودی‌ها و ساختار خروجی‌ها معین می‌شود؛ اما تعداد نرون‌های لایه میانی به سادگی قابل تعیین نیست و باید به صورت تجربی یا با روش‌های بهینه‌سازی تعیین شوند (Richards & Jia, 2006).

در حالت دوم و پنجم روش پیشنهادی در بخش ۰ تعیین تعداد نرون‌های لایه میانی با ترسیم نمودار ضریب کاپا انجام گرفته است. سقف بررسی تعداد نرون‌های لایه میانی ۶۰ در نظر گرفته شده است. این تعداد بسیار بیشتر از پیشنهاد روابط تجربی برای تعیین تعداد نرون‌های لایه‌های میانی است و برای اطمینان خاطر بیشتر انتخاب شده است.

۲-۶- وزن‌دهی اولیه

روش آموزش گرادینان نزولی چند ایراد مهم و اساسی دارد. این روش به شدت به شکل سطح خطا و مقادیر وزن‌های اولیه و برخی پارامترهای دیگر حساس است. سطح خطا ممکن است دارای کمینه محلی، چندحالتی

در مرحله انتخاب ویژگی‌های ورودی بهینه با استفاده از الگوریتم ژنتیک معلوم شد که کروموزوم با طول بزرگ در استخراج ویژگی‌ها مشکل‌ساز است و ویژگی‌ها به درستی انتخاب نمی‌شوند و زمان اجرا را نیز به شدت افزایش می‌دهد. به همین دلیل در این مرحله هشت ویژگی بافت برای هریک از سه باند مرئی به‌طور جداگانه تولید می‌شود و سپس میانگین آنها وارد بردار ویژگی می‌شود. هشت ویژگی بافت برای هریک از دو تصویر در ابعاد پنجره ۳×۳، ۵×۵ و ۷×۷ (۴۸ ویژگی بافت) به بردار ویژگی معرفی می‌شوند. با اضافه کردن شش ویژگی طیفی، ابعاد بردار ویژگی تا ۵۴ افزایش می‌یابد. پس از این مراحل، بردار ویژگی استخراجی به الگوریتم ژنتیک معرفی می‌شود و بهترین ویژگی‌های طیفی و مکانی انتخاب می‌شوند. در کدگذاری کروموزوم برای انتخاب ویژگی‌های مکانی، بیت‌های با مقدار یک، نماینده وجود یک ویژگی و بیت‌های با مقدار صفر، نماینده وجود نداشتن ویژگی هستند. مشخصات الگوریتم ژنتیک به کار گرفته شده در پژوهش حاضر در جدول ۲ آمده است.

۲-۵- معماری شبکه

توانایی شبکه عصبی در فرایند یادگیری و فرایند تعمیم شبکه تا حد بالایی به انتخاب معماری درست بستگی دارد. تعداد کم نرون‌های مخفی باعث آموزش ناکافی شبکه می‌شود، در حالی که استفاده از نرون‌های میانی

1. tournament
2. crossover
3. two point

۲-۷- حالت‌های مورد بررسی

همان‌طور که در بخش هدف تحقیق اشاره شد، در پژوهش حاضر شش حالت مختلف برای آشکارسازی تغییرات هریک با دو رویکرد DMC و PCC مورد مقایسه قرار گرفتند. جدول ۳ مشخصات حالت‌های بررسی شده را با جزئیات کامل نشان می‌دهد. حالت ششم روش اصلی تحقیق است که انتظار می‌رود به صحیح‌ترین نتایج منجر شود.

یا مشتق‌ناپذیر باشد. در این شرایط رسیدن به همگرایی مطلوب در فرایند آموزش شبکه چندان آسان نخواهد بود. وزن‌دهی‌های مختلف روی روند آموزش تأثیر می‌گذارند و نتایج متفاوتی به دست می‌دهند (Hertz et al., 1991). بر اساس دلایل مذکور، در پژوهش حاضر پس از مشخص شدن معماری شبکه عصبی، شبکه با وزن‌دهی‌های متفاوت مبتنی بر روش وزن‌دهی اولیه نگوین و ویدرو^۱ (۱۹۹۰) چندین بار آموزش داده شد تا بهترین عملکرد به دست آید.

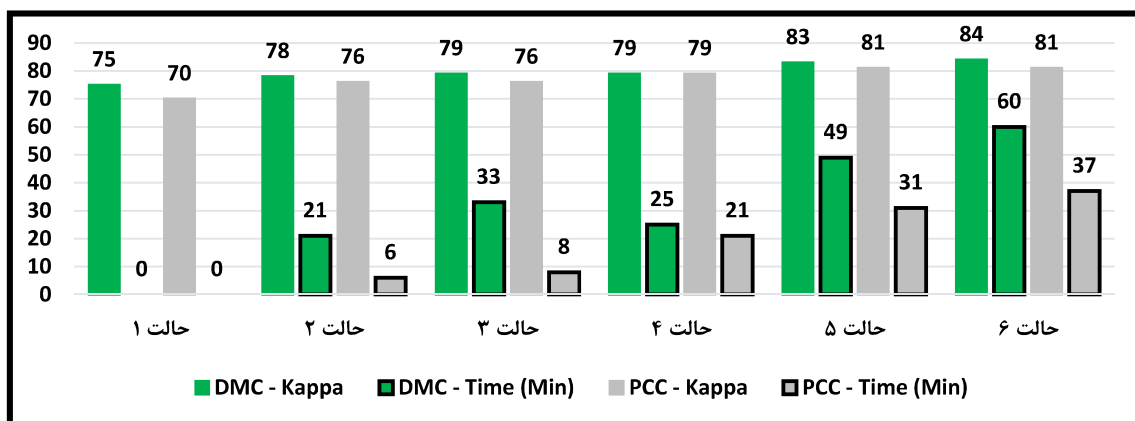
جدول ۳. حالت‌های شش‌گانه مورد بررسی به منظور آشکارسازی تغییرات^۱

حالت	ویژگی‌های مورد استفاده	روش مورد استفاده	هدف
۱	باند‌های اصلی تصویر	طبقه‌بندی بیشترین شباهت	روش طبقه‌بندی بیشترین شباهت به عنوان روش سنتی و مبنای اولیه ارزیابی دقت سایر روش‌ها مورد بررسی قرار گرفته است.
۲	باند‌های اصلی تصویر	طبقه‌بندی شبکه‌های عصبی با وزن‌دهی ثابت اولیه به منظور تعیین تعداد نرون‌های لایه میانی	تعیین تعداد نرون‌های لایه میانی
۳	باند‌های اصلی تصویر	چند بار اجرای طبقه‌بندی شبکه‌های عصبی با تعداد نرون‌های تعیین شده از حالت ۲ و با وزن‌دهی‌های اولیه متفاوت برای دستیابی به بالاترین صحت ممکن	از بین بردن حساسیت شبکه عصبی به وزن‌دهی اولیه و دستیابی به بالاترین صحت ممکن
۴	باند‌های اصلی تصویر در کنار ویژگی‌های مکانی بافت با ابعاد پنجره ۳×۳، ۵×۵ و ۷×۷	الگوریتم ژنتیک باینری به منظور تعیین ویژگی‌های بهینه با تابع شایستگی ضرب کاپای طبقه‌بندی بیشترین شباهت	تعیین ویژگی‌های اصلی و طیفی بهینه
۵	ویژگی‌های بهینه انتخاب شده حالت ۴	طبقه‌بندی شبکه‌های عصبی با وزن‌دهی ثابت اولیه به منظور تعیین تعداد نرون‌های لایه میانی	تعیین تعداد نرون‌های لایه میانی
۶	ویژگی‌های بهینه انتخاب شده حالت ۴	چند بار اجرای طبقه‌بندی شبکه‌های عصبی با تعداد نرون‌های تعیین شده از حالت ۴ و با وزن‌دهی‌های اولیه متفاوت برای دستیابی به بالاترین صحت ممکن	از بین بردن حساسیت شبکه عصبی به وزن‌دهی اولیه و دستیابی به بالاترین صحت ممکن

۳- نتایج

پس از پیاده‌سازی ۶ حالت، مشخص شد که از نظر صحت طبقه‌بندی رویکرد طبقه‌بندی مستقیم چندزمانی درمقایسه با مقایسه پس از طبقه‌بندی، در همه حالت‌ها نتایج بهتری دارد، هرچند زمان اجرای آن طولانی‌تر است. علت دقت کمتر روش مقایسه پس از طبقه‌بندی را می‌توان در خطای تجمعی ناشی از مقایسه نقشه‌ها دانست. به‌طور کلی، در میان شش حالت پیاده‌سازی شده، حالت ۶ بهترین صحت را درمقایسه با حالت‌های دیگر دارد. شکل ۲ ضریب کاپای هر یک از شش حالت مورد بررسی را به‌همراه زمان اجرای الگوریتم برحسب دقت نشان می‌دهد. هرچند روش پیشنهادی (حالت ۶) زمان اجرای طولانی‌تری از سایر روش‌ها دارد، اما درمقایسه با طبقه‌بندی سنتی بیشترین شباهت، نتایج را ۹ درصد و درمقایسه با حالت طبقه‌بندی شبکه‌های عصبی با باندهای اصلی تصویر نتایج را ۶ درصد بهبود می‌بخشد. در حالت چهارم، هدف

انتخاب بهینه ویژگی‌ها با استفاده از الگوریتم ژنتیک بود. جدول ویژگی‌های انتخابی این روش را که از میان ۵۴ ویژگی برای رویکرد طبقه‌بندی مستقیم انتخاب شده‌اند، نشان می‌دهد. استفاده از این ویژگی‌ها در روش طبقه‌بندی بیشترین شباهت ۴ درصد و در روش طبقه‌بندی شبکه عصبی ۶ درصد صحت نتایج را بهبود بخشیده است. این ویژگی‌ها به‌عنوان ورودی در حالت پنجم و ششم نیز به‌کار گرفته شده‌اند. در حالت پنجم، هدف انتخاب تعداد نرون‌های لایه میانی شبکه عصبی بوده است. در این حالت با اختصاص الگوریتم ثابت به‌جای اختصاص تصادفی وزن‌های اولیه به نرون‌های شبکه روی انتخاب تعداد نرون‌های لایه میانی تمرکز می‌شود. شکل نمودار تغییرات ضریب کاپا را برحسب تعداد نرون‌های لایه میانی برای رویکرد طبقه‌بندی مستقیم حالت پنج نشان می‌دهد. این نمودار نشان می‌دهد که ۲۶ نرون در لایه میانی منجر به بیشترین ضریب کاپا (۸۳ درصد) شده است.




شکل ۲. نمودار مقایسه نتایج شش حالت مختلف پیاده‌سازی شده از نظر صحت طبقه‌بندی و زمان اجرای الگوریتم


جدول ۴. ویژگی‌های انتخابی با استفاده از الگوریتم ژنتیک در رویکرد طبقه‌بندی مستقیم (حالت چهارم)

شماره باند	۱	۳	۴	۲۸	۲۹	۳۰	۴۷	۵۱
ویژگی	باند قرمز	باند آبی	میانگین	باند قرمز	باند سبز	باند آبی	میانگین	آنتروپی
ابعاد پنجره	-	-	۳×۳	-	-	-	۷×۷	۷×۷
تاریخ	۲۰۰۴	۲۰۰۴	۲۰۰۴	۲۰۱۰	۲۰۱۰	۲۰۱۰	۲۰۱۰	۲۰۱۰

آشکارسازی تغییرات مناطق شهری مبتنی بر شبکه‌های عصبی، ویژگی‌های مکانی و الگوریتم ژنتیک با استفاده از...



شکل ۴. نمودار ضریب کاپا برحسب تعداد نرون لایه میانی (حالت پنجم)



شکل ۵. نمودار ضریب کاپا در وزن‌دهی‌های مختلف (حالت ششم)


بر افزایش دقت در کلاس‌های مختلف تغییر بیان می‌کند. همان‌طور که مشاهده می‌شود وارد کردن پارامترهای بهینه بافت در آشکارسازی تغییرات به‌روشن شبکه عصبی کم‌وبیش صحت کاربر و تولیدکننده اغلب کلاس‌های تغییر را بهبود بخشیده است. در کلاس‌هایی هم که کاهش صحت وجود داشته مقدار آن اندک بوده است.

۴- بحث و نتیجه‌گیری

روش پیشنهادی در پژوهش حاضر، روشی برای استخراج اطلاعات تغییر با استفاده از تصاویر چندطیفی بزرگ‌مقیاس و دوزمانی است. هدف ارائه روشی بود که با به‌کارگیری ویژگی‌های بافت، شبکه‌های عصبی و الگوریتم ژنتیک توانایی ارائه اطلاعات کافی را درباره آشکارسازی تغییرات شهری با صحت بالا داشته باشد. در این پژوهش شش حالت مختلف بررسی شد.

همان‌طور که پیشتر اشاره شد، شبکه عصبی نسبت به وزن‌دهی اولیه حساس (اصطلاحاً ناپایدار) است و وزن‌دهی‌های مختلف به نتایج مختلف منجر خواهند شد. به‌همین دلیل پس از آنکه تعداد نرون‌های لایه میانی در حالت پنجم مشخص شد به‌طور تصادفی ۳۰ بار وزن‌دهی‌های اولیه تصادفی به‌کار گرفته می‌شود تا مشکل ناپایداری شبکه از بین برود. نمودار شکل تغییرات ضریب کاپا را در این ۳۰ بار وزن‌دهی اولیه برای حالت ششم و رویکرد طبقه‌بندی مستقیم نشان می‌دهد. بالاترین ضریب کاپای به‌دست‌آمده در این مرحله (بالاترین صحت بین روش‌های بررسی‌شده) برابر ۸۴ درصد است.

نمودار شکل ۶ به‌صورت مقایسه‌ای صحت کاربر و تولیدکننده را در طبقه‌بندی مستقیم شبکه عصبی در حالت ۳ و حالت ۶ نشان می‌دهد و تأثیر پارامتر بافت را



شکل ۶. نمودار صحت تولیدکننده و صحت کاربر در حالت‌های ۳ و ۶ برای ده کلاس تغییرات

به منظور رفع مشکل حساسیت شبکه به وزن‌دهی اولیه شبکه ۳۰ بار اجرا شد تا بالاترین صحت ممکن فراهم شود. حالت ششم که در سه مرحله انتخاب ویژگی، تعیین تعداد نرون‌های لایه میانی، و اجرای چندین بار شبکه صورت گرفت، به ضریب کاپای ۸۴ درصد منجر شد. هرچند این حالت مستلزم زمان اجرای طولانی تری بود، درمقایسه با حالت‌های دیگر بهترین عملکرد را داشت. درنهایت می‌توان گفت که در پژوهش حاضر مزیت شبکه عصبی به‌روشنی بیشترین شباهت و مزیت انتخاب بهینه ویژگی، تعیین معماری مناسب برای شبکه‌های عصبی و اجرای چندباره شبکه به اثبات رسید.

آنچه برای کامل‌تر شدن تحقیق حاضر به ذهن می‌رسد، در نظر گرفتن سایر ویژگی‌های مکانی مانند مورفولوژی و ویژگی‌های آماری بافت است که ممکن است نتایج را بهبود ببخشد. آنالیز مؤلفه اصلی و ترکیب آن با الگوریتم ژنتیک برای بهینه‌کردن ویژگی‌های مکانی از دیگر زمینه‌های قابل بررسی است.

در تمامی حالت‌ها دو رویکرد مقایسه پس از طبقه‌بندی و طبقه‌بندی مستقیم چندزمانی پیاده‌سازی شدند. ساده‌ترین حالت (حالت اول) طبقه‌بندی با ویژگی‌های طیفی با الگوریتم بیش‌ترین شباهت و برترین حالت (حالت ششم) آشکارسازی با طبقه‌بندی شبکه عصبی و ویژگی‌های بهینه بافت همراه با انتخاب معماری بهینه شبکه و اجرای چند بار شبکه عصبی است.

در تمامی شش حالت، رویکرد طبقه‌بندی مستقیم برتری خود را بر روش مقایسه پس از طبقه‌بندی نشان داد. همان‌طور که انتظار می‌رفت در نظر گرفتن ویژگی‌های مکانی متن‌تصویر در تصاویر بزرگ‌مقیاس و در منطقه شهری نتایج را بهبود می‌بخشد، زیرا در این مناطق تنوع و ناهمگونی طیفی دیده می‌شود. این ویژگی‌ها در حالت‌های ۴، ۵ و ۶ صحت نتایج را درمقایسه با حالت‌های ۱، ۲ و ۳ که فاقد ویژگی‌های بافت بودند، به ترتیب ۴، ۵ و ۵ درصد افزایش می‌دهد. تعیین تعداد نرون‌های لایه میانی شبکه عصبی در حالت‌های ۲ و ۵ با ترسیم نمودار تغییرات کاپای حاصل از طبقه‌بندی برحسب تعداد نرون‌ها صورت گرفت.

۵- منابع

- Benediktsson, J.A., Swain P.H. & Ersoy O.K., 1990, **Neural Network Approaches versus Statistical Methods in Classification of Multisource Remote Sensing Data**, Geoscience and Remote Sensing, IEEE Transactions on 28(4), PP. 540-552.
- Bruzzone, L. & Serpico, S.B., 1997, **An Iterative Technique for the Detection of Land-cover Transitions in Multitemporal Remote-sensing Images**, Geoscience and Remote Sensing, IEEE Transactions on 35(4), PP. 858-867.
- Chen, C., Chen, K.S. & Chang, J., 1995, **Neural Network for Change Detection of Remotely Sensed Imagery**.
- Chini, M., Pacifici, F., Emery, W.J., Pierdicca, N. & Del Frate, F., 2008, **Comparing Statistical and Neural Network Methods Applied to very high Resolution Satellite Images Showing Changes in Man-made Structures at Rocky Flats**, Geoscience and Remote Sensing, IEEE Transactions on 46(6), PP. 1812-1821.
- Coppin, P.R. & Bauer, M.E., 1996, **Digital Change Detection in Forest Ecosystems with Remote Sensing Imagery**, Remote Sensing Reviews 13(3), PP. 207-234.
- Dai, X. & Khorram, S., 1998, **The Effects of Image Misregistration on the Accuracy of Remotely Sensed Change Detection**, Geoscience and Remote Sensing, IEEE Transactions on 36(5), PP. 1566-1577.
- Haralick, R.M., Shanmugam K. & Dinstein I.H., 1973, **Textural Features for Image Classification**, Systems, Man and Cybernetics, IEEE Transactions on(6), PP. 610-621.
- Heermann, P.D. & Khazenie N., 1992, **Classification of Multispectral Remote Sensing Data using a Back-propagation Neural Network**, Geoscience and Remote Sensing, IEEE Transactions on 30(1), PP. 81-88.
- Hertz, J., Krogh A. & Palmer, R.G., 1991, **Introduction to the Theory of Neural Computation**, Westview press.
- Kabir, S., He, D. & Hussina, W., 2010, **Texture Analysis of IKONOS Satellite Imagery for Urban Land use and Land Cover Classification**, Imaging Science Journal, 58(3), PP. 163-170.
- Liu, Y., Starzyk J.A. & Zhu Z., 2007, **Optimizing Number of Hidden Neurons in Neural Networks**, Artificial Intelligence and Applications.
- Long, D., 1999, **Remotely Sensed Change Detection based on Artificial Neural Networks**, Photogrammetric engineering and remote sensing, 65(10), PP. 1187-1194.
- Neagoe, V.E., Neghina, M. & Datcu, M., 2012, **Neural Network Techniques for Automated Land-Cover Change Detection in Multispectral Satellite Time**

- Series Imagery**, International Journal of Mathematical Models and Methods in Applied Sciences, 6(1), PP. 130-139.
- Nguyen, D. & Widrow, B., 1990, **Improving the Learning Speed of 2-layer Neural Networks by Choosing Initial Values of the Adaptive Weights**, Neural Networks, 1990 IJCNN International Joint Conference on, IEEE.
- Pacifici, F., Del Frate, F., Solimini, C. & Emery, W.J., 2007, **An Innovative Neural-net Method to Detect Temporal Changes in High-resolution Optical Satellite Imagery**, Geoscience and Remote Sensing, IEEE Transactions on 45(9), PP. 2940-2952.
- Paola, J. & Schowengerdt R., 1995, **A Review and Analysis of Backpropagation Neural Networks for Classification of Remotely-sensed Multi-spectral Imagery**, International Journal of Remote Sensing, 16, PP. 3033-3033.
- Paola, J.D. & Schowengerdt, R.A., 1995, **A Detailed Comparison of Backpropagation Neural Network and Maximum-likelihood Classifiers for Urban Land Use Classification**, Geoscience and Remote Sensing, IEEE Transactions on 33(4), PP. 981-996.
- Pu, R., Gong, P., Tian, Y., Miao, X., Carruthers, R.I. & Anderson G.L., 2008, **Invasive Species Change Detection using Artificial Neural Networks and CASI Hyperspectral Imagery**, Environmental monitoring and assessment, 140(1-3), PP. 5-32.
- Richards, J.A. & Jia, X., 2006, **Remote Sensing Digital Image Analysis: an introduction**, Springer Verlag.
- Rumelhart, D.E., Hintont G.E. & Williams, R.J., 1986, **Learning Representations by Back-propagating Errors**, Nature 323(6088), PP. 533-536.
- Zhang, Y., 1999, **Optimisation of Building Detection in Satellite Images by Combining Multispectral Classification and Texture Filtering**, ISPRS journal of photogrammetry and remote sensing, 54(1), PP. 50-60.