

طبقه‌بندی اطلاعات سنجنده‌های مرئی-حرارتی هوایی مبتنی بر مدل‌های یادگیری ژرف

قاسم عبدی^{۱*}، فرهاد صمدزادگان^۲

^۱ دکتری فتوگرامتری - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران
ghasem.abdi@ut.ac.ir

^۲ استاد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران
samadz@ut.ac.ir

(تاریخ دریافت آذر ۱۳۹۶، تاریخ تصویب اسفند ۱۳۹۶)

چکیده

با رشد و توسعه سیستم‌های تصویربرداری هوابرد و یا فضابرد در حوزه سنجش از دور، ادغام اطلاعات سنجنده‌های چندگانه به منظور دستیابی به دانش تکمیلی نسبت به عوارض و به پیرو آن طبقه‌بندی دقیق داده‌های سنجش از دور مورد توجه بسیاری از محققین این حوزه و مهندسی علوم زمین قرار گرفته است. از سوی دیگر، مدل‌های یادگیری ژرف با افزایش سطح اتوماسیون و همچنین بهبود دقت طبقه‌بندی تصاویر با بهره‌گیری از روش‌های استخراج ویژگی ژرف، تبدیل به یکی از موضوعات پرمخاطب در حوزه پردازش تصاویر شده است. در این تحقیق، روشی نوین به منظور طبقه‌بندی دقیق اطلاعات سنجنده‌های چندگانه مبتنی بر مدل‌های یادگیری ژرف ارائه شده است. در این زمینه، ویژگی‌های ژرف با در نظرگیری بعد طیفی-مکانی داده‌های ورودی استخراج، و سپس یک طبقه‌بندی کننده فازی جهت آموزش این ویژگی‌ها و همچنین بهینه‌سازی مدل یادگیری ژرف استفاده می‌گردد. پس از طبقه‌بندی داده‌های ورودی به صورت جداگانه، با بکارگیری برخی قوانین در سطح تصمیمات اتخاذ شده، اطلاعات به دست آمده با یکدیگر ادغام شده و در نهایت، پس‌پردازشی مبتنی بر وابستگی‌های متقابل بین عوارض در قالب اطلاعات زمینه خارجی به منظور افزایش دقت نتایج طبقه‌بندی مورد استفاده قرار می‌گیرد. به منظور ارزیابی توان اجرایی روش پیشنهادی در این تحقیق، مجموعه‌ای از آزمون‌های مقایسه‌ای بر داده‌های منتشر شده توسط کمیته فنی تلفیق داده‌ها و آنالیز تصاویر جامعه بین‌المللی سنجش از دور و مهندسی علوم زمین در سال ۲۰۱۴ میلادی، صورت گرفته است. در مقایسه روش‌های طبقه‌بندی مبتنی بر مدل‌های یادگیری ژرف با طبقه‌بندی کننده‌های مرسوم، دقت کلی طبقه‌بندی اطلاعات سنجنده‌ی مرئی ۳،۹۱٪، فراحارثی ۶،۶۵٪ و چندگانه ۲،۸۱٪ بهبود یافته است. به علاوه، در نظرگیری وابستگی‌های متقابل بین عوارض در قالب اطلاعات زمینه خارجی و یا قوانین پس‌پردازشی به منظور کاهش و یا حذف خطاهای مرسوم روش‌های طبقه‌بندی پیکسل‌مبنا، موجب بهبود دقت کلی ۲،۷۱٪ می‌گردد. همچنین، در مقایسه روش پیشنهادی طبقه‌بندی اطلاعات سنجنده‌های چندگانه با طبقه‌بندی کننده‌های اطلاعات سنجنده‌ی مرئی و یا فراحارثی، دقت کلی طبقه‌بندی ۷،۵۷٪ و ۲۲،۲۲٪ بهبود یافته است.

واژگان کلیدی: ادغام در سطح تصمیم‌گیری، تصاویر حرارتی، شبکه عصبی اتوانکدر، شبکه عصبی کانولوشن، یادگیری ژرف

* نویسنده رابط

۱- مقدمه

در سال‌های اخیر، استفاده از تصاویر و داده‌های سنجنش از دور با هدف نظارت و برنامه‌ریزی در محیط‌های شهری، مناطق کشاورزی و غیره با رشد روزافزونی مواجه شده است. هر چند تکنولوژی ساخت سنجنده‌های سنجنش از دور با پیشرفت‌های شگرفی مواجه بوده است و عملاً با قابلیت این سنجنده‌ها در ثبت ویژگی‌های مختلف از سطح زمین، امکان شناسایی عوارض مختلف مبتنی بر تحلیل‌های طیفی، مکانی و ساختاری^۱ فراهم شده است، با این حال هر سنجنده دارای قدرت تفکیک مکانی، طیفی و زمانی محدودی می‌باشد و امکان استفاده از یک سنجنده به صورت مجزا در تفسیر دقیق و جامع مناطق پیچیده وجود ندارد [۱]. از اینرو در سال‌های اخیر، با رشد و توسعه سیستم‌های تصویربرداری هوابرد و یا فضابرد در حوزه سنجنش از دور [۷-۲] و همچنین با در نظرگیری قابلیت دسترسی، به‌هنگام بودن، پوشش و کارایی بالای داده‌های فوق، استفاده از سیستم‌های چندسنجنده‌ای^۲ در آنالیز و پردازش اطلاعات با هدف بکارگیری مجموعه‌ای از مشاهدات مطرح شده است. از سوی دیگر، نیاز به الگوریتم‌های تلفیق داده^۳ به منظور استخراج اطلاعات کاربردی و تهیه نقشه‌های به‌هنگام از مجموعه مشاهدات وجود دارد. در این راستا، تلفیق داده‌ها و آنالیز تصاویر نقش بسیار مؤثری در تحلیل مسائل کاربردی ایفا می‌نماید. در میان مسائل کاربردی مطرح، طبقه‌بندی عوارض شهری با هدف تهیه نقشه موضوعی و همچنین شناسایی پوشش زمینی، یکی از پردازش‌های کلیدی در استخراج اطلاعات کاربردی و چالش برانگیزترین موضوعات تحقیقاتی در حال انجام به دلیل تنوع کلان این عوارض و همچنین پیچیدگی بالای آن‌ها می‌باشد [۶]، [۸]. علیرغم مطالعات صورت گرفته در زمینه ادغام اطلاعات سنجنده‌های چندگانه با رویکرد طبقه‌بندی عوارض شهری، همچنان چالش‌هایی در مواجهه با در نظر گرفتن هم‌زمان داده‌هایی با مشخصه‌های گوناگون از سنجنده‌های مجزا وجود دارد.

پیشرفت‌های اخیر سیستم‌های تصویربرداری حرارتی^۴ باعث شده است که تمایل به استفاده از این تصاویر در کنار اطلاعات سنجنده‌های مرئی^۵ با رویکرد طبقه‌بندی عوارض مذکور، مورد توجه بسیاری از محققین در جوامع سنجنش از دور و مهندسی علوم زمین قرار گیرد [۹]. در این راستا، تصاویر مرئی با قدرت تفکیک مکانی و وضوح تصویری بسیار بالا نقش مهمی در طبقه‌بندی عوارض شهری ایفا می‌نماید؛ با این وجود، فقدان افزونگی اطلاعات طیفی این سنجنده‌ها منجر به عدم توانمندی تشخیص صحیح عوارض با اطلاعات طیفی یکسان می‌گردد [۶]. از سوی دیگر، رشد و توسعه سیستم‌های تصویربرداری حرارتی، قابلیت برداشت هم‌زمان تصاویری با ۱۰۰ها باند طیفی باریک به منظور شناسایی عوارض مختلف صرف‌نظر از شرایط محیطی و به پیرو آن افزایش دقت طبقه‌بندی را ایجاد کرده است [۹]. با توجه به مشخصه‌های متفاوت داده‌های مرئی-حرارتی، این سنجنده‌ها مکمل یکدیگر می‌باشند و استفاده هم‌زمان از مشاهدات این سنجنده‌ها، امکان استفاده از مزایای آن‌ها را فراهم می‌آورد. به منظور طبقه‌بندی عوارض شهری مبتنی بر ادغام اطلاعات سنجنده‌های مرئی-حرارتی، الگوریتم‌ها و پردازش‌های گوناگونی ارائه شده است. در این زمینه، استخراج ویژگی، انتخاب طبقه‌بندی کننده و پارامترهای مدل‌سازی بهینه آن در بسیاری از مطالعات تطبیقی به عنوان عوامل بسیار تأثیرگذار در تعیین دقت طبقه‌بندی عوارض شهری تعیین و مورد تحلیل واقع شده‌اند؛ از سوی دیگر، مدل‌های یادگیری ژرف^۶ با افزایش سطح اتوماسیون و همچنین بهبود دقت طبقه‌بندی تصاویر با بهره‌گیری از روش‌های استخراج ویژگی ژرف^۷، تبدیل به یکی از موضوعات پرمخاطب در حوزه پردازش تصاویر شده است [۲۱-۱۰]؛ بدین منظور در این تحقیق، روشی نوین به منظور طبقه‌بندی دقیق اطلاعات سنجنده‌های چندگانه مبتنی بر مدل‌های یادگیری ژرف ارائه گردیده و سپس، مزایای قابل توجه روش پیشنهادی نسبت به روش‌های مرسوم توسط مجموعه‌ای از آزمون‌های مقایسه‌ای بیان شده است.

۴ Thermal Imaging Systems

۵ Visual Data

۶ Deep Learning

۷ Deep Features

۱ Spectral, Spatial and Structural Features

۲ Multi-Sensor Systems

۳ Data Fusion

۲- مروری بر مطالعات انجام شده

لیا و همکاران^۱ (۲۰۱۵) نتایج طبقه‌بندی عوارض شهری بر داده‌های منتشر شده توسط کمیته فنی تلفیق داده‌ها و آنالیز تصاویر جامعه بین‌المللی سنجش از دور و مهندسی علوم زمین در سال ۲۰۱۴ میلادی^۲ را ارائه کردند [۹]: مقاله برتر طبقه‌بندی به تلفیق اطلاعات سنجنده‌های مرئی و فراحتراتی^۳ با رویکرد طبقه‌بندی سلسله مراتبی^۴ و مقاله برتر نوآوری به توسعه روشی نوین جهت تلفیق و آنالیز اطلاعات سنجنده‌های چندگانه و چندتفکیکی^۵ اختصاص داده شده است. در این روش، قدرت تفکیک مکانی تصاویر مرئی و فراحتراتی با استفاده از استراتژی نمونه‌برداری، یکسان‌سازی می‌شود، سپس ویژگی‌های طیفی-بافتی نظیر ویژگی‌های بافتی درجه اول^۶ و دوم^۷ از تصویر مرئی، شاخص مورفولوژیکی ساختمانی، شاخص گیاهی از ادغام تصاویر مرئی و فراحتراتی و پنج مؤلفه اصلی از آنالیز مؤلفه‌های اصلی^۸ تصویر فراحتراتی استخراج می‌شود. در ادامه، طبقه‌بندی عوارض به صورت سلسله مراتبی بر مبنای تلفیق ویژگی‌های استخراج شده^۹ صورت گرفته و در نهایت پس‌پردازشی بر اساس رأی‌گیری حداکثری^{۱۰}، قطعه‌بندی MS^{۱۱} و در نظرگیری برخی قوانین مبتنی بر دانش^{۱۲} با هدف افزایش دقت نتایج طبقه‌بندی پیکسل‌مبنا انجام می‌گیرد. در روش پیشنهادی مقاله برتر نوآوری، اطلاعات سنجنده مرئی به منظور استخراج ویژگی‌های مورفولوژیکی و همچنین استفاده در فیلتر هدایت‌پذیر^{۱۳} با هدف افزایش قدرت تفکیک مکانی تصویر فراحتراتی استفاده می‌شود. در نهایت، طبقه‌بندی عوارض شهری بر مبنای تلفیق ویژگی‌های استخراج شده و با استفاده از طبقه‌بندی کننده ماشین بردار پشتیبان^{۱۴} صورت می‌گیرد. پس از این دوره، این داده‌ها به عنوان یک چالش اساسی در حوزه تلفیق

داده‌ها و آنالیز تصاویر و همچنین به منظور توسعه و تحقیق‌های بیشتر بر روی آن، در دسترس عموم قرار گرفت. در این راستا، لو و همکاران^{۱۵} (۲۰۱۵) با ادغام اطلاعات سنجنده‌ها در سطح تصمیم‌گیری^{۱۶}، به طبقه‌بندی عوارض شهری پرداختند [۶]. ابتدا، روشی نوین مبتنی بر مدل SLDA^{۱۷} به منظور استخراج ویژگی‌های متمایز از تصویر فراحتراتی و به پیرو آن، طبقه‌بندی با استفاده از الگوریتم ماشین بردار پشتیبان ارائه شده است. سپس، تصویر مرئی بر مبنای ویژگی‌های استخراج شده طیفی-بافتی آن و با استفاده از الگوریتم ماشین بردار پشتیبان طبقه‌بندی می‌شود. در نهایت، روشی شیء‌مبنا، طبقه‌بندی کننده‌های فوق را در سطح تصمیم‌گیری به منظور تشخیص عوارض شهری تلفیق می‌نماید. لی و همکاران^{۱۸} (۲۰۱۵) به تلفیق اطلاعات سنجنده‌های مرئی و فراحتراتی با رویکرد طبقه‌بندی سلسله مراتبی و به منظور تشخیص عوارض شهری پرداختند [۸]. ابتدا، پیش‌پردازشی به منظور بررسی تمایز ویژگی‌های طیفی استخراج شده و بر اساس شاخص‌های JMD^{۱۹} و TD^{۲۰} صورت می‌گیرد. سپس، داده‌ها مبتنی بر تلفیق تصویر فراحتراتی و قطعه‌بندی تصویر مرئی استخراج، و شناسایی مابقی عوارض با استفاده از اطلاعات طیفی-مکانی تصویر مرئی و مبتنی بر طبقه‌بندی کننده ماشین بردار پشتیبان صورت می‌گیرد. در نهایت، روشی شیء‌مبنا، طبقه‌بندی کننده فوق را در سطح تصمیم‌گیری به منظور تشخیص عوارض شهری تلفیق می‌نماید. اسلامی و محمدزاده^{۲۱} (۲۰۱۶) با پیش‌پردازشی مبتنی بر الگوریتم ISAC^{۲۲} تصویر فراحتراتی را از لحاظ رادیومتریکی تصحیح کرده و با استفاده از الگوریتم SPPP^{۲۳} ابعاد آن را به چندطیفی^{۲۴} کاهش داده‌اند. در ادامه، قدرت تفکیک مکانی تصویر چندطیفی را با تصویر مرئی و بر اساس استراتژی نمونه‌برداری، یکسان‌سازی کرده‌اند. همچنین، این تصاویر با استفاده از ۱۶ نقطه مشترک و بر اساس الگوریتم چندجمله‌ای تناظریابی هندسی شده‌اند.

^{۱۵} Lu et al.

^{۱۶} Decision-Level Fusion

^{۱۷} Semi-Supervised Local Discriminant Analysis

^{۱۸} Li et al.

^{۱۹} Jeffries-Matusita Distance

^{۲۰} Transformed Divergence

^{۲۱} Eslami and Mohammadzadeh

^{۲۲} In-Scene Atmospheric Compensation

^{۲۳} Sequential Parametric Projection Pursuit

^{۲۴} Multispectral

^۱ Liao et al.

^۲ 2014 IEEE GRSS Data Fusion Contest

^۳ Thermal Hyperspectral

^۴ Hierarchical Classification

^۵ Multiresolution

^۶ Occurrence Statistics

^۷ Co-Occurrence Statistics

^۸ Principle Component Analysis (PCA)

^۹ Feature-Level Fusion

^{۱۰} Majority Voting

^{۱۱} Mean Shift Segmentation

^{۱۲} Knowledge-Based

^{۱۳} Guided Filtering Scheme

^{۱۴} Support Vector Machine (SVM)

سپس، طبقه‌بندی بر اساس تلفیق ویژگی‌های طیفی استخراج شده و الگوریتم ماشین بردار پشتیبان صورت می‌گیرد. در نهایت، پس‌پردازشی با در نظرگیری برخی قوانین مبتنی بر دانش به منظور افزایش دقت نتایج طبقه‌بندی پیکسل‌مبنا انجام می‌گیرد [۲۲]. صمدزادگان و همکاران^۱ (۲۰۱۷) با پیش‌پردازشی مبتنی بر استراتژی نمونه‌برداری، قدرت تفکیک مکانی تصویر فراحارتری را با تصویر مرئی همسان‌سازی کرده و سپس با استفاده از روش آنالیز مؤلفه‌های اصلی ابعاد طیفی آن را کاهش داده‌اند. در ادامه، مجموعه وسیعی از ویژگی‌ها شامل طیفی-بافتی، شاخص گیاهی، DMP^۲، AP^۳، زمین‌آماري^۴، SFS^۵ و توصیف‌گرهای آماری^۶ استخراج شده است. سپس، مجموعه‌ای از بهینه‌ترین ویژگی‌ها به همراه پارامترهای مدل‌سازی طبقه‌بندی کننده ماشین بردار پشتیبان با استفاده از الگوریتم بهینه‌سازی جستجوی فاخته^۷ تعیین می‌گردد. در نهایت، پس‌پردازشی بر اساس رأی‌گیری حداکثری، به منظور افزایش دقت نتایج طبقه‌بندی پیکسل‌مبنا انجام می‌گیرد [۲۳]. اسلامی و محمدزاده (۲۰۱۷) با پیش‌پردازشی مبتنی بر الگوریتم ISAC تصویر فراحارتری را از لحاظ رادیومتریکی تصحیح کرده و با استفاده از الگوریتم SPPP ابعاد آن را به چندطیفی کاهش داده‌اند. در ادامه، قدرت تفکیک مکانی تصویر چندطیفی را با تصویر مرئی و بر اساس استراتژی نمونه‌برداری، یکسان‌سازی کرده‌اند. سپس، طبقه‌بندی عوارض شهری به صورت سلسله مراتبی بر مبنای تلفیق ویژگی‌های استخراج شده طیفی-مکانی از تصویر مرئی و طیفی-بافتی از تصویر چندطیفی حرارتی صورت می‌گیرد. در مرحله اول، درختان و پوشش گیاهی با استفاده از ویژگی‌های طیفی-مکانی تصویر مرئی شناسایی می‌شوند. در مرحله بعد، پوشش زمینی، سقف ساختمانی و جاده‌ها بر اساس تلفیق ویژگی‌های فوق استخراج می‌شوند. در مرحله انتهایی، تلفیق نتایج مراحل قبل و همچنین پس‌پردازشی با در نظرگیری برخی قوانین مبتنی بر دانش به منظور افزایش دقت نتایج طبقه‌بندی پیکسل‌مبنا انجام می‌گیرد [۲۴].

^۱ Samadzadegan et al.

^۲ Differential Morphological Profile

^۳ Attribute Profile

^۴ Geostatistical

^۵ Structural Feature Set

^۶ Local Statistical Descriptors

^۷ Cuckoo Search

در این بخش، روش‌های متعددی برای طبقه‌بندی عوارض شهری داده‌های منتشر شده توسط کمیته فنی تلفیق داده‌ها و آنالیز تصاویر جامعه بین‌المللی سنجش از دور و مهندسی علوم زمین در سال ۲۰۱۴ میلادی، با رویکرد نوآوری در توسعه و یا طبقه‌بندی کاربردی ارائه شده است. در این زمینه، روش‌های استخراج ویژگی، انتخاب طبقه‌بندی کننده و پارامترهای مدل‌سازی بهینه آن در بسیاری از مطالعات تطبیقی به عنوان عوامل بسیار تأثیرگذار در تعیین دقت طبقه‌بندی عوارض شهری تعیین و مورد تحلیل واقع شده‌اند [۲۹-۲۵]. مبتنی بر جمع‌بندی و مقایسه اجمالی روش‌های ارائه شده، استراتژی‌های موجود توانمندی کافی برای در نظرگیری چالش‌های مطرح شده در فوق و با هدف طبقه‌بندی داده‌های سنجش از دور را ندارند [۳۰]؛ از سوی دیگر، مدل‌های یادگیری ژرف با افزایش سطح اتوماسیون و همچنین بهبود دقت طبقه‌بندی تصاویر با بهره‌گیری از روش‌های استخراج ویژگی ژرف، تبدیل به یکی از موضوعات پرمخاطب در حوزه پردازش تصاویر شده است [۲۱-۱۰]. بدین منظور در این تحقیق، روشی نوین به منظور طبقه‌بندی دقیق اطلاعات سنجنده‌های چندگانه مبتنی بر مدل‌های یادگیری ژرف ارائه گردیده و سپس، مزایای قابل توجه روش پیشنهادی نسبت به روش‌های مرسوم توسط مجموعه‌ای از آزمون‌های مقایسه‌ای بر داده‌های منتشر شده توسط کمیته فنی تلفیق داده‌ها و آنالیز تصاویر جامعه بین‌المللی سنجش از دور و مهندسی علوم زمین در سال ۲۰۱۴ میلادی، بیان شده است.

۳- یادگیری ژرف

طراحی و توسعه معماری‌های نوین الهام گرفته از این واقعیت است که مغز پستانداران مبتنی بر معماری ژرف و با استفاده از تصریح ورودی در سطوح مختلف انتزاع، برای سیستم بصری بطور خاص سازمان‌دهی شده است. بنابراین، بسیاری از محققین با الهام گرفتن از مدل معماری مغز انسان، معماری‌های نوین ژرف را به عنوان جایگزینی برای معماری‌های مرسوم مطرح کرده‌اند [۳۱]. در ادامه، روش‌های استخراج ویژگی ژرف مطرح در حوزه سنجش از دور و مهندسی علوم زمین شامل شبکه‌های

عصبی اتوانکدر^۱ و کانولوشن^۲ به صورت تفضیلی بیان می گردد [۲۱]، [۳۲-۳۷].

۳-۱- توصیف گره های شبکه عصبی اتوانکدر

اتوانکدر یک شبکه عصبی مصنوعی پیش رونده^۳ متشکل از لایه های ورودی، پنهانی و خروجی، و به عنوان موفق ترین و شناخته شده ترین نمونه از روش های یادگیری بدون نظارت در حوزه بینایی کامپیوتری مطرح می باشد. این مدل مبتنی بر استراتژی پس انتشار^۴ [۳۸] و با هدف برآوردی از داده های ورودی با کارآمدی بیشتر نسبت به داده های اولیه، آموزش داده می شود. در این زمینه، تعداد واحدهای لایه پنهانی به عنوان تنها قید مطرح در اتوانکدرهای کلاسیک مورد بحث و بررسی قرار می گیرد و در صورت کمتر بودن آن از تعداد ورودی ها، اتوانکدر دارای عملکردی مشابه با روش های کاهش ابعاد و با هدف آموزش نگاشتی از فضای بیشینه ورودی به فضای کمینه ویژگی مطرح می گردد. در این راستا، می توان تنظیمات مختلفی به تابع هدف در حین آموزش اتوانکدر اعمال، و ویژگی های متعددی استخراج نمود. به عنوان مثال، اتوانکدرهای پراکنده^۵ (شکل ۱) یک مورد خاص از اتوانکدرهای مرسوم و با در نظرگیری فعال بودن بخشی از واحدها در حین آموزش، می باشند:

نگاشتی از فضای ورودی $x \in \mathbb{R}^d$ به فضای لایه پنهانی h (تحت عنوان k) با k رشته عصبی (تحت عنوان واحد)، مبتنی بر تابع انکدر به صورت زیر تعریف می گردد:

$$f(x) = h = \alpha_f(W_1 x + b_1) \quad (1)$$

در رابطه فوق، $\alpha_f: \mathbb{R} \mapsto \mathbb{R}$ نمایانگر تابع فعال سازی^۶ غیرخطی همانند توابع سیگموئید لجستیک، تانژانت هذلولوی و یا ReLU^۷ می باشد؛ این تابع بر اساس ماتریس وزن $W_1 \in \mathbb{R}^{k \times d}$ با وزن های آموزش دیده اتصالات فضای ورودی به لایه پنهانی و بردار بایاس $b_1 \in \mathbb{R}^k$ مشخص می شود. سپس، لایه خروجی شبکه بر مبنای نگاشتی از نتایج لایه

پنهانی h به برآوردی از فضای ورودی $\hat{x} \in \mathbb{R}^d$ و با استفاده از تابع دکدر مجزایی به صورت زیر محاسبه می گردد:

$$g(f(x)) = \hat{x} = \alpha_g(W_2 h + b_2) \quad (2)$$

در این رابطه، α_g تابع فعال سازی، $W_2 \in \mathbb{R}^{d \times k}$ ماتریس دکدر و $b_2 \in \mathbb{R}^d$ بردار بایاس می باشند که در حین نگاشت از لایه پنهانی به خروجی آموزش داده می شوند.

برآوردی از مجموعه پارامترهای اتوانکدر، بر اساس کمینه سازی خطای بازسازی میان داده های ورودی و خروجی و بر اساس تابع زیان خاصی^۸ انجام می گیرد. در این راستا، تابع زیان به منظور کمینه سازی خطای کمترین مربعات نرمالیزه شده و با هدف بهینه سازی، به صورت زیر بیان می گردد:

$$J_{AE}(\theta) = \frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \|x_i - \hat{x}_i\|^2 \right) \quad (3)$$

در رابطه فوق، m تعداد نمونه های آموزشی و $\|\cdot\|$ نمایانگر فاصله اقلیدسی می باشد. عمدتاً به منظور جلوگیری از بیش تطابق نمودن مدل، یک ترم تضعیف وزن^۹ به تابع هزینه فوق اضافه می گردد. همچنین بسیاری از محققین با بهره گیری از شواهد و مدارک علوم اعصاب مبنی بر نزدیکی شبکه های پراکنده به پاسخ های نورون های بیولوژیکی [۳۹]، [۴۰]، از معماری اتوانکدرهای پراکنده جهت بهره مندی از پراکندگی آن در سیستم های توسعه داده شده، استفاده کرده اند. در این زمینه، محققین با تعریف ثابت پراکندگی ρ ، در تلاش برای نزدیکی متوسط فعال سازی واحدهای پنهان به سمت مقدار ρ با استفاده از جریمه آن با معیار واگرایی کولبک-لیبلر^{۱۰} می باشند:

$$KL(\rho \parallel \hat{\rho}_u) = \rho \log \frac{\rho}{\hat{\rho}_u} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_u} \quad (4)$$

لذا، کمینه ترین فاصله در حالت $\hat{\rho}_u = \rho$ به دست می آید و با افزایش $\hat{\rho}_u$ ، این معیار تمایل به سمت بی نهایت خواهد داشت. در نهایت، تابع هزینه اتوانکدر پراکنده متشکل از خطای بازسازی اتوانکدرهای کلاسیک و همچنین ترم اصلاحی پراکندگی به صورت زیر بازنویسی می گردد:

^۸ Loss Function

^۹ Weight Decay Term

^{۱۰} Kullback-Leibler (KL) Divergence

^۱ Autoencoder Neural Networks

^۲ Convolutional Neural Networks (CNNs)

^۳ Feed-Forward Artificial Neural Network

^۴ Back-Propagation


^۵ Sparse Autoencoder (SAE)

^۶ Activation Function

^۷ Rectified Linear Units Function

$$J_{SAE}(\theta) = J_{AE}(\theta) + \beta \sum_{j=1}^k KL(\rho || \hat{\rho}_u) \quad (5)$$

در رابطه فوق، پارامتر β نمایانگر میزان اهمیت تنظیم‌کننده پراکندگی می‌باشد. به منظور کمینه‌سازی تابع هزینه فوق، مجموعه‌ی وزن‌ها با محاسبه‌ی مشتقات جزئی از J_{SAE} و همچنین بکارگیری الگوریتم پس‌انتشار، به‌هنگام می‌شوند [۳۸]؛ بدین ترتیب فرآیند آموزش اتوانکدر، پس از چندی تکرار به‌سمت کمینه‌ترین مقدار خود همگرا می‌گردد. به‌علاوه، خروجی نهایی این معماری (با بهبود نحوه‌ی بیان داده‌ها نسبت به برداشت خام آن‌ها) قابلیت بهره‌برداری مستقیم در طبقه‌بندی‌کننده‌ها و به‌پیرو آن بهینه‌سازی مدل یادگیری ژرف به‌صورت نظارت شده و با استفاده از استراتژی پس‌انتشار را دارد [۳۸]، [۴۱].



شکل ۱- مدل‌سازی اتوانکدر پراکنده: الف) تک لایه‌ای و ب) پشته‌ای

۳-۲- توصیف‌گرهای شبکه عصبی کانولوشن

شبکه عصبی کانولوشن به‌عنوان شاخه‌ای از شبکه‌های عصبی مصنوعی پیش‌رونده و ژرف در حوزه یادگیری ماشین مطرح می‌باشد و به‌صورت موفقیت‌آمیزی در تحلیل داده‌های بصری مورد استفاده قرار گرفته است. ساختار شبکه‌های عصبی کانولوشن از فرایندهای بیولوژیکی [۴۲] الهام گرفته است که در آن، الگوی ارتباطی بین نورون‌ها بر مبنای سیستم بینایی حیوانات سازمان‌دهی شده است. این ساختار به‌گونه‌ای است که تک نورون‌ها تنها در یک ناحیه محدود به تحریک (ناحیه پذیرش)^۱ پاسخ می‌دهند؛ همچنین، نواحی پذیرش نورون‌های مختلف با یکدیگر هم‌پوشانی جزئی داشته بطوریکه تمام میدان دید را پوشش می‌دهند. به‌عبارت

دیگر، این نوع از شبکه‌های عصبی از پرسپترون‌های چندلایه^۲ به منظور کمینه‌سازی پیش‌پردازش‌ها استفاده می‌کنند [۴۳]. از اینرو، شبکه‌های عصبی کانولوشن نسبت به طبقه‌بندی‌کننده‌های دیگر از پیش‌پردازش‌های نسبتاً کمتری برخوردار می‌باشد و این بدین معنی است که، این شبکه‌ها نسبت به آموزش فیلترها بطور خودکار مبادرت ورزیده در حالی که روش‌های مرسوم به‌صورت دستی^۳ این فرایند را انجام می‌داده‌اند. لذا، از عمده مزایای شبکه‌های عصبی کانولوشن می‌توان به مستقل بودن نسبت به دانش پیشین و افراد خبره به منظور استخراج عوارض اشاره کرد. شبکه‌های عصبی کانولوشن نیز همانند اتوانکدرها، متشکل از لایه‌های ورودی، پنهانی (عمدتاً شامل لایه‌های کانولوشن، فعال‌سازی، ادغام^۴ و تمام متصل^۵) و خروجی می‌باشند. علاوه بر این، لایه طبقه‌بندی‌کننده با هدف برآورد احتمال متعلق بودن به کلاس‌های عوارض، در انتها و پس از مابقی لایه‌های معماری قرار می‌گیرد. در ادامه، توضیحات مرتبط با هر یک از این لایه‌ها با رویکرد بیان معماری‌های مرسوم در شبکه‌های عصبی کانولوشن ارائه گردیده است.

کانولوشن‌ها: لایه کانولوشن به‌عنوان هسته اصلی شبکه‌های عصبی کانولوشن شامل مجموعه‌ای از فیلترهای قابل یادگیری (یا کرنل) با نواحی پذیرش محدود و قابلیت گسترش آن توسط عمق کاملی از فضای ورودی می‌باشد. در حین استراتژی پیش‌رونده، هر فیلتر در سراسر فضای ورودی کانولو شده و سپس، نقشه فعال‌سازی دوبعدی هر فیلتر مبتنی بر ضرب نقطه‌ای میان فیلتر و فضای ورودی ایجاد می‌گردد. بدین ترتیب، شبکه نسبت به آموزش فیلترهایی با توان فعال‌سازی در حالی که ویژگی خاصی در مکانی از فضای ورودی شناسایی می‌نمایند، مبادرت می‌ورزد. در نهایت، خروجی لایه کانولوشن با تجميع تمامی نقشه‌های فعال‌سازی فیلترها در راستای بعد عمق ایجاد می‌گردد؛ هر المان از این خروجی بیانگر نتیجه یک نورون با ناحیه پذیرشی در فضای ورودی و اشتراک پارامترهایی با مابقی نورون‌ها در همان نقشه فعال‌سازی می‌باشد. به‌علاوه، ابعاد مکانی لایه خروجی کانولوشن

^۲ Multilayer Perceptrons

^۳ Hand-Engineered

^۴ Pooling

^۵ Fully Connected


^۱ Receptive Field

نورون‌های ورودی به این لایه، نورون‌های موجود در این لایه قادر به برآورد بیشینه احتمال متعلق بودن به کلاس‌های عوارض مبتنی بر رابطه زیر می‌باشند:

$$y_i = W_i x_i + b_i \quad (V)$$

در رابطه فوق، x_i بردار ورودی، W_i ماتریس وزن و b_i بردار بایاس می‌باشند.

همانند اتوانکدرها، خروجی نهایی این معماری (با بهبود نحوه بیان داده‌ها نسبت به برداشت خام آن‌ها) قابلیت بهره‌برداری مستقیم در طبقه‌بندی کننده‌ها و به پیرو آن بهینه‌سازی مدل یادگیری ژرف به صورت نظارت شده و با استفاده از استراتژی پس‌انتشار را دارد [۳۸]، [۴۱]. معماری شبکه‌های عصبی کانولوشن به صورت کلی در شکل (۲) نمایش داده شده است.



شکل ۲- معماری کلی شبکه‌های عصبی کانولوشن

۴- روش پیشنهادی

همانگونه که در بخش‌های پیشین بیان گردید، با رشد و توسعه سیستم‌های تصویربرداری هوابرد و یا فضابرد در حوزه سنجش از دور، ادغام اطلاعات سنجنده‌های چندگانه به منظور دستیابی به دانش تکمیلی نسبت به عوارض و به پیرو آن طبقه‌بندی دقیق داده‌های سنجش از دور امری اجتناب‌ناپذیر در این حوزه و مهندسی علوم زمین می‌باشد. در این زمینه، روش‌های مرسوم توانمندی کافی برای در نظرگیری چالش‌های مطرح شده در روش‌های استخراج ویژگی، انتخاب طبقه‌بندی کننده و پارامترهای مدل‌سازی بهینه آن با هدف طبقه‌بندی داده‌های سنجش از دور را نداشته و از سوی دیگر، روند رشد و توسعه معماری‌های یادگیری ژرف در حوزه سنجش از دور و مهندسی علوم زمین با افزایش سطح اتوماسیون و همچنین بهبود دقت طبقه‌بندی تصاویر مبتنی بر روش‌های استخراج ویژگی ژرف، بسیار چشمگیر می‌باشد. از اینرو در این تحقیق،

(H_o, W_o, D_o) ، به عنوان تابعی از ابعاد فضای ورودی (H_i, W_i) ، ابعاد فیلتر f ، تعداد فیلتر N ، اندازه گام s و مقدار لایه‌گذاری با صفر p ، توسط رابطه زیر محاسبه می‌گردد:

$$H_o = \frac{H_i - f + 2p}{s} + 1, W_o = \frac{W_i - f + 2p}{s} + 1, D_o = N \quad (۶)$$

توابع غیرخطی: توابع غیرخطی پس از لایه کانولوشن و به منظور مدل‌سازی نحوه فعال‌سازی نورون‌های خاص در لایه‌ای از شبکه بکار می‌روند. در این زمینه، توابع غیرخطی متعددی پیشنهاد شده است که از میان آن‌ها توابع سیگموئید، تانژانت هذلولوی و ReLU متداول‌تر و پرکاربردتر می‌باشند. به عنوان نمونه، تابع فعال‌سازی ReLU به عنوان کارآمدترین تابع غیرخطی از منظر پیچیدگی محاسباتی [۴۴]، مقادیر منفی را صفر و مقادیر مثبت را ثابت نگه می‌دارد.

لایه‌های ادغام: عمدتاً، استراتژی‌های ادغام پس از لایه کانولوشن و با هدف کاهش فضای ورودی از لحاظ ابعاد مکانی بکار می‌روند. در این راستا، اطلاعات ورودی مبتنی بر حرکت یک فیلتر در سراسر فضای ورودی جمع، و به لایه ادغام جهت کاهش قدرت تفکیک مکانی ارسال می‌گردد. بدین منظور، تصویر ورودی به زیربخش‌های متعددی (بدون هم‌پوشانی) تقسیم‌بندی می‌شود و سپس، به ازای هر زیربخش وابسته به استراتژی ادغام آن (بیشینه مقدار و یا میانگین)، یک مقدار جایگزین آن زیربخش می‌گردد. به علاوه، استراتژی ادغام نیز با تعریف پارامتر گام مشخصی قابلیت کنترل ابعاد خروجی را دارا می‌باشد. بدین ترتیب، بکارگیری این استراتژی منجر به کارآمدی هر چه بیشتر شبکه از طریق مستقل بودن نسبت به پارامترهای انتقال و همچنین کاهش افزونگی اطلاعات و به پیرو آن پیچیدگی محاسباتی، می‌گردد [۳۵].

لایه تمام متصل: عمدتاً، پس از استخراج ویژگی‌های ژرف بر اساس لایه‌های کانولوشن و ادغام، یک لایه تمام متصل در انتهای معماری در نظر گرفته می‌شود که هر نورون آن به تمامی خروجی نورون‌های لایه قبلی متصل می‌باشد. بدین ترتیب، با در نظرگیری فعال بودن تمامی


^۱ Depth

^۲ Stride

^۳ Zero-Padding

روشی نوین به منظور طبقه‌بندی دقیق اطلاعات سنجنده‌های چندگانه مبتنی بر مدل‌های یادگیری ژرف ارائه شده است. در این راستا، ویژگی‌های ژرف با در نظرگیری بعد طیفی-مکانی داده‌های ورودی استخراج، و سپس یک طبقه‌بندی کننده فازی جهت آموزش این ویژگی‌ها و همچنین بهینه‌سازی مدل یادگیری ژرف استفاده می‌گردد. پس از طبقه‌بندی داده‌های ورودی به صورت جداگانه، با بکارگیری برخی قوانین در سطح تصمیمات اتخاذ شده، اطلاعات به دست آمده با یکدیگر ادغام شده و در نهایت، پس‌پردازشی مبتنی بر وابستگی‌های

متقابل بین عوارض در قالب اطلاعات زمینه خارجی به منظور افزایش دقت نتایج طبقه‌بندی مورد استفاده قرار می‌گیرد. بدین ترتیب، روش پیشنهادی از چهار مرحله: (۱) استخراج ویژگی‌های ژرف، (۲) طبقه‌بندی و بهینه‌سازی معماری شبکه، (۳) ادغام طبقه‌بندی کننده‌ها در سطح تصمیم‌گیری و (۴) پس‌پردازش تشکیل گردیده است. در شکل (۳) ساختار و مراحل روش پیشنهادی نمایش داده شده و توضیحات مرتبط با هر مرحله در بخش‌های بعدی ارائه گردیده است.



شکل ۳- ساختار و مراحل روش پیشنهادی

۴-۱- استخراج ویژگی‌های ژرف

به منظور طبقه‌بندی عوارض شهری با استفاده از ادغام اطلاعات سنجنده‌های چندگانه، در اولین مرحله بایستی ویژگی‌های مناسب بر اساس ماهیت داده‌های سنسور از دور ورودی، استخراج شوند [۴۵]. در این راستا، توصیفگرهای شبکه‌های عصبی اتوانکدر و کانولوشن مبتنی بر مدل معماری‌های جداول (۲-۱) استخراج می‌شوند.

جدول ۱- معماری شبکه‌های عصبی اتوانکدر

سنجنده	I_1	AE_2	AE_3	AE_4	F_5	O_6
مرئی	$5 \times 5 \times 3$	۱۵	۱۵	۱۵	FC	1×7
فراحتراتی	1×110	۲۵	۲۵	۲۵	FC	1×7

لایه‌های مذکور به صورت I ورودی، AE اتوانکدر، F تمام متصل و O خروجی می‌باشند.

جدول ۲- معماری شبکه‌های عصبی کانولوشن

سنجنده	I_1	numFilters			F_8	O_9
		S_3	S_5	C_6		
مرئی	$7 \times 7 \times 3$	2×2	4×4	3×3	-	1×7
فراحتراتی	1×208	1×2	1×6	1×7	FC	1×7

لایه‌های مذکور به صورت I ورودی، C کانولوشن، S ادغام، F تمام متصل و O خروجی می‌باشند.

۲-۴- طبقه‌بندی و بهینه‌سازی معماری شبکه

تابع بیشینه هموار^۱ تعمیم‌یافته تابع رگرسیون لجستیک می‌باشد که در روش‌های طبقه‌بندی متعددی از جمله رگرسیون لجستیک چندجمله‌ای، آنالیز افتراقی خطی، طبقه‌بندی کننده بیزین ساده و همچنین شبکه عصبی مصنوعی استفاده می‌شود [۴۶]. در راستای طبقه‌بندی داده‌های مدل یادگیری ژرف، تابع بیشینه هموار برآوردی از احتمال انتساب ورودی x_i به کلاس k را به صورت زیر محاسبه می‌نماید:

$$p(y = k | \bar{x} = x_i) = \frac{e^{(s_i)}}{\sum_j e^{(s_j)}} \quad (۸)$$

در این رابطه، s بیانگر امتیاز کسب شده کلاس k از آخرین لایه معماری شبکه می‌باشد. به علاوه، تعیین مقادیر بهینه پارامترهای شبکه با استفاده از بهینه‌سازی تابع هزینه و همچنین پارامتر تنظیم λ به صورت زیر تعریف می‌گردد:

$$L = \sum_n -\log \left(\frac{e^{(s_i)}}{\sum_j e^{(s_j)}} \right) + \lambda R(W) \quad (۹)$$

۳-۴- ادغام طبقه‌بندی کننده‌ها در سطح تصمیم‌گیری

ادغام در سطح تصمیم‌گیری به عنوان بالاترین سطح از ادغام داده‌ها و با هدف استفاده‌ی همزمان از تصمیمات چندین طبقه‌بندی کننده متفاوت مبتنی بر الگوریتم‌های منطقی و یا آماری مناسب، و استخراج نتیجه‌ای است که هیچ یک از طبقه‌بندی کننده‌های انفرادی قادر به ایجاد آن نباشند. در این تحقیق، پرکاربردترین روش‌های ادغام طبقه‌بندی کننده‌ها مبتنی بر خروجی مطلق شامل بیزین ساده^۲ و فضای دانش رفتاری^۳ با هدف ادغام طبقه‌بندی کننده‌های اطلاعات سنجنده‌های مرئی و فراحتراتی مورد استفاده قرار گرفته است [۴۸]، [۴۹].

۴-۴- پس پردازش

عمدتاً، نقشه‌های طبقه‌بندی عوارض استخراج شده از روش‌های طبقه‌بندی پیکسل‌مبنا شامل تعداد بسیار زیادی

از خطاهای طبقه‌بندی ناشی از ناهمگونی داده‌ها می‌باشند [۷]. به منظور کاهش و یا حذف این خطاها مبتنی بر وابستگی‌های متقابل بین عوارض در قالب اطلاعات زمینه خارجی، روش قطعه‌بندی چندتفکیکی^۴ با هدف تقسیم‌بندی داده‌های تصویری به نواحی بدون هم‌پوشانی مکانی استفاده می‌گردد. در این راستا، این روش با در نظرگیری اولین پیکسل تصویری و ادغام مکرر آن با پیکسل‌های همسایگی به منظور ایجاد عوارضی با ابعاد بزرگتر و با در نظر داشتن معیار همگنی محلی (بیانگر میزان شباهت بین عوارض تصویری مجاور)، به تقسیم‌بندی داده‌های تصویری مبادرت می‌ورزد [۵۰]. پس از قطعه‌بندی داده‌های تصویری، برچسب نهایی هر قطعه بر مبنای رأی‌گیری حداکثری و با در نظرگیری توصیف‌گرهای مختلف ساختاری و همچنین وابستگی‌های متقابل بین عوارض در قالب اطلاعات زمینه خارجی، ایجاد می‌گردد. جدول (۳) نمایانگر قوانین پس‌پردازشی با هدف کاهش و یا حذف خطاهای مرسوم روش‌های طبقه‌بندی پیکسل‌مبنا می‌باشد.

جدول ۳- قوانین پس‌پردازشی

قوانین	رأی‌گیری حداکثری
اگر در همسایگی عوارض جاده‌ای وجود داشته باشد، آنگاه عارضه جاده می‌باشد.	جاده‌ها
اگر در همسایگی عوارض جاده‌ای وجود نداشته باشد، آنگاه عارضه با بیشینه مرزی عوارض همسایگی یکی می‌باشد.	
اگر نسبت ابعاد و یا مساحت کمتر از حدآستانه باشد، آنگاه عارضه درخت می‌باشد.	درختان
اگر نسبت ابعاد و یا مساحت بیشتر از حدآستانه باشد، آنگاه عارضه گیاه می‌باشد.	
اگر نسبت ابعاد کمتر از حدآستانه باشد، آنگاه عارضه سقف قرمز می‌باشد.	سقف قرمز
اگر نسبت ابعاد بیشتر از حدآستانه و در همسایگی عوارض جاده‌ای وجود داشته باشد، آنگاه عارضه جاده می‌باشد.	
اگر نسبت ابعاد بیشتر از حدآستانه و در همسایگی عوارض جاده‌ای وجود نداشته باشد، آنگاه عارضه با بیشینه مرزی عوارض همسایگی یکی می‌باشد.	

^۴ Multiresolution Image Segmentation

^۱ Softmax Regression

^۲ Naïve Bayesian (NB)

^۳ Behavior Knowledge Space (BKS)

ادامه‌ی جدول ۳- قوانین پس‌پردازشی

سقف خاکستری	اگر نسبت ابعاد کمتر از حدآستانه باشد، آنگاه عارضه سقف خاکستری می‌باشد.
	اگر نسبت ابعاد بیشتر از حدآستانه و در همسایگی عوارض جاده‌ای وجود داشته باشد، آنگاه عارضه جاده می‌باشد.
	اگر نسبت ابعاد بیشتر از حدآستانه و در همسایگی عوارض جاده‌ای وجود نداشته باشد، آنگاه عارضه با بیشینه مرزی عوارض همسایگی یکی می‌باشد.
سقف بتنی	اگر نسبت ابعاد کمتر از حدآستانه باشد، آنگاه عارضه سقف بتنی می‌باشد.
	اگر نسبت ابعاد بیشتر از حدآستانه و در همسایگی عوارض جاده‌ای وجود داشته باشد، آنگاه عارضه جاده می‌باشد.
	اگر نسبت ابعاد بیشتر از حدآستانه و در همسایگی عوارض جاده‌ای وجود نداشته باشد، آنگاه عارضه با بیشینه مرزی عوارض همسایگی یکی می‌باشد.
گیاهان	اگر رأی‌گیری حداکثری عارضه گیاه باشد آنگاه عارضه گیاه می‌باشد.
پوشش زمینی	اگر رأی‌گیری حداکثری عارضه پوشش زمینی باشد آنگاه عارضه پوشش زمینی می‌باشد.
عوارض شهری	اگر تمام همسایگی عوارض جاده‌ای باشد، آنگاه عارضه جاده می‌باشد.

پروازی ۸۰۷ متر بالای سطح زمین و به‌صورت زمین‌مرجع در تاریخ ۲۱ام ماه مه سال ۲۰۱۳ میلادی اخذ شده است. نقشه‌ی اطلاعات زمینی داده‌های منتشر شده دارای هفت کلاس از عوارض شهری می‌باشد؛ به دلیل شباهت طیفی میان کلاس‌های فوق، این داده‌ها دارای پیچیدگی‌های متعددی برای طبقه‌بندی عوارض شهری می‌باشد و به همین دلیل می‌تواند داده‌ی مناسبی به منظور ارزیابی توانایی روش‌های ارائه شده باشد. در این راستا، مبتنی بر نقشه‌ی اطلاعات زمینی ارائه شده و به‌صورت تصادفی از هر کلاس به تعداد ۱۰۰ نمونه‌ی آموزشی به منظور آموزش طبقه‌بندی کننده انتخاب و سپس، قدرت تعمیم و دقت روش‌های ارائه شده با استفاده از مابقی نمونه‌های نقشه‌ی اطلاعات زمینی تحت عنوان داده‌های تست مورد ارزیابی قرار خواهد گرفت.



شکل ۴- تصاویر: (الف) مرئی، (ب) فراحرارتی و (ج) نقشه اطلاعات زمینی

به منظور ارزیابی توان اجرایی روش پیشنهادی، مجموعه‌ای از آزمون‌های مقایسه‌ای بر داده‌های فوق‌الذکر نسبت به طبقه‌بندی کننده‌های مرسوم شامل درخت تصمیم‌گیری، آنالیز تفکیک خطی^۱، بیزین ساده، نزدیکترین K همسایگی^۲ و ماشین‌های بردار پشتیبان صورت گرفته است؛ شایان ذکر است توصیف‌گرهای مختلفی با هدف اندازه‌گیری ویژگی‌هایی از نوع طیفی-بافتی به منظور طبقه‌بندی تصاویر فراحرارتی (شامل مؤلفه‌های اصلی مبتنی بر تخمین‌گرهای بعد ذاتی EV ، HS ^۳ و NH) و مرئی (شامل پاسخ‌های طیفی، شاخص‌های گیاهی، گلبور، آماری و شبه‌واریوگرام) با استفاده از طبقه‌بندی کننده‌های مرسوم مورد بهره‌برداری قرار گرفته است. ابتدا، مجموعه‌ای از آزمون‌های مقایسه‌ای بین عملکرد طبقه‌بندی کننده‌های مختلف در طبقه‌بندی تصویر مرئی صورت پذیرفت (جدول ۴ و اشکال ۵-۶). همانطور که از نتایج مشخص می‌باشد، بهترین عملکرد طبقه‌بندی کننده‌های مرسوم متعلق به ماشین‌های بردار پشتیبان (با دقت کلی: ۸۵٫۸۱٪ و ضریب کاپا: ۰٫۸۱) می‌باشد؛ در حالیکه، روش‌های طبقه‌بندی مبتنی

۵- پیاده‌سازی و ارزیابی نتایج

به منظور ارزیابی توانایی روش‌های ارائه شده در این تحقیق، نسبت به پیاده‌سازی و بکارگیری آن‌ها در طبقه‌بندی عوارض شهری داده‌های منتشر شده توسط کمیته فنی تلفیق داده‌ها و آنالیز تصاویر جامعه بین‌المللی سنسجس از دور و مهندسی علوم زمین در سال ۲۰۱۴ میلادی (شکل ۴)، اقدام گردید. در این راستا، تصویر فراحرارتی با استفاده از سیستم تصویربرداری فراطیفی هوایی در محدوده‌ی مادون قرمز با طول موج بلند برداشت و ثبت گردیده است؛ این سیستم تصویربرداری شامل ۸۴ باند در محدوده‌ی طیفی ۷٫۸ الی ۱۱٫۵ میکرومتر با قدرت تفکیک مکانی در حدود یک متر می‌باشد. تصویر مرئی نیز از سری تصاویر رنگی اخذ شده در خطوط مختلف پروازی و با قدرت تفکیک مکانی در حدود ۲۰ سانتی‌متر تشکیل گردیده است. همچنین، داده‌های مذکور از یک منطقه شهری نزدیک معادن تنفورد (در کبک کانادا)^۱ با ارتفاع

^۱ Linear Discriminant Analysis (DA)

^۲ K-Nearest Neighbor (KNN)

^۳ Eigenvalue

^۴ HPS Signal Subspace Identification by Minimum Error

^۵ Noise-Whitened Harsanyi-Farrand-Chang

^۱ Thetford Mines in Québec, Canada

سپس، مجموعه‌ای از آزمون‌های مقایسه‌ای بین عملکرد طبقه‌بندی کننده‌های مختلف در طبقه‌بندی تصویر فراحارارتی صورت پذیرفت (جداول ۵-۶ و اشکال ۷-۸). بهترین عملکرد طبقه‌بندی کننده‌های مرسوم متعلق به ماشین‌های بردار پشتیبان (با دقت کلی: ۶۸,۴۲٪ و ضریب کاپا: ۰,۵۸) می‌باشد؛ در حالیکه، روش‌های طبقه‌بندی مبتنی بر مدل‌های یادگیری ژرف (شبکه عصبی اتوانکدر با دقت کلی: ۶۸,۹۵٪ و ضریب کاپا: ۰,۵۸ و شبکه عصبی کانولوشن با دقت کلی: ۷۵,۰۷٪ و ضریب کاپا: ۰,۶۷) با بکارگیری اطلاعات طیفی-مکانی به صورت همزمان و به پیرو آن استخراج ویژگی‌های ژرف از داده‌های ورودی، عملکرد به مراتب بهتری (با در نظرگیری افزایش سطح اتوماسیون و همچنین بهبود ۶,۶۵٪ دقت طبقه‌بندی) نسبت به طبقه‌بندی کننده‌های مرسوم از خود نشان داده‌اند. به علاوه، مواد معدنی سیلیکات بخش عمده‌ی مواد تشکیل دهنده‌ی سطح زمین و عوارض ساخته به دست بشر، قادر به نمایش ویژگی‌های طیفی بنیادینی در گستره مادون قرمز با طول موج بلند بوده و می‌تواند به منظور افزایش دقت طبقه‌بندی اطلاعات سنجنده‌ی مرئی مورد استفاده قرار گیرد.

جدول ۵- مقایسه دقت کلی طبقه‌بندی کننده‌های تصویر فراحارارتی

CNN	SAE	SVM	KNN	NB	DA	DT	
۰,۷۵	۰,۶۹	۰,۵۱	۰,۴۸	۰,۵۳	۰,۵۳	۰,۵۱	EV
		۰,۶۸	۰,۶۷	۰,۶۵	۰,۶۶	۰,۶۱	HS
		۰,۶۵	۰,۶۴	۰,۶۵	۰,۶۵	۰,۶۴	NH

جدول ۶- مقایسه دقت طبقه‌بندی کننده‌های تصویر فراحارارتی

CNN	SAE	SVM	KNN	NB	DA	DT	
۰,۹۵	۰,۹۳	۰,۹۰	۰,۹۲	۰,۹۱	۰,۹۱	۰,۸۸	۱
۰,۵۴	۰,۳۳	۰,۳۶	۰,۵۰	۰,۴۲	۰,۲۵	۰,۲۹	۲
۰,۵۴	۰,۴۶	۰,۶۰	۰,۵۵	۰,۵۶	۰,۴۸	۰,۴۱	۳
۰,۵۳	۰,۴۷	۰,۴۰	۰,۴۰	۰,۳۷	۰,۴۴	۰,۳۹	۴
۰,۶۷	۰,۵۰	۰,۴۱	۰,۴۳	۰,۳۲	۰,۳۲	۰,۴۶	۵
۰,۵۵	۰,۵۲	۰,۵۶	۰,۳۷	۰,۵۶	۰,۵۹	۰,۴۸	۶
۰,۷۷	۰,۶۶	۰,۶۶	۰,۶۳	۰,۴۴	۰,۴۵	۰,۵۲	۷
۰,۷۵	۰,۶۹	۰,۶۸	۰,۶۷	۰,۶۵	۰,۶۶	۰,۶۴	دقت
۰,۶۷	۰,۵۸	۰,۵۸	۰,۵۶	۰,۵۴	۰,۵۴	۰,۵۱	کاپا


مقادیر مشخص شده نمایانگر اشتباهات در سطح اعتبار ۵٪ می‌باشند. کلاس‌های ۱-۷ به صورت جاده‌ها، درختان، سقف قرمز، سقف خاکستری، سقف بتنی، گیاهان و پوشش زمینی می‌باشند.

بر مدل‌های یادگیری ژرف (شبکه عصبی اتوانکدر با دقت کلی: ۸۵,۹۷٪ و ضریب کاپا: ۰,۸۱ و شبکه عصبی کانولوشن با دقت کلی: ۸۹,۷۲٪ و ضریب کاپا: ۰,۸۶) با بکارگیری اطلاعات طیفی-مکانی به صورت همزمان و به پیرو آن استخراج ویژگی‌های ژرف از داده‌های ورودی، عملکرد به مراتب بهتری (با در نظرگیری افزایش سطح اتوماسیون و همچنین بهبود ۳,۹۱٪ دقت طبقه‌بندی) نسبت به طبقه‌بندی کننده‌های مرسوم از خود نشان داده‌اند. از سوی دیگر، طبقه‌بندی عوارض شهری مبتنی بر اطلاعات سنجنده‌ی مرئی، به دلیل شباهت اطلاعات طیفی این سنجنده میان عوارضی نظیر جاده‌ای با سقف خاکستری و درختان با گیاهان، منجر به عدم توانمندی تمایز و تشخیص صحیح این عوارض و به پیرو آن کاهش دقت طبقه‌بندی می‌گردد.


جدول ۴- مقایسه دقت طبقه‌بندی کننده‌های تصویر مرئی

CNN	SAE	SVM	KNN	NB	DA	DT	
۰,۸۸	۰,۹۰	۰,۸۶	۰,۷۹	۰,۶۰	۰,۶۸	۰,۶۵	۱
۰,۹۱	۰,۸۵	۰,۸۱	۰,۸۰	۰,۵۷	۰,۷۶	۰,۸۲	۲
۰,۹۵	۰,۹۰	۰,۹۳	۰,۸۷	۰,۴۸	۰,۸۸	۰,۸۴	۳
۰,۸۳	۰,۷۴	۰,۶۱	۰,۶۸	۰,۰۱	۰,۶۶	۰,۷۴	۴
۰,۹۳	۰,۸۴	۰,۹۶	۰,۹۵	۰,۹۸	۰,۹۷	۰,۹۴	۵
۰,۹۳	۰,۷۸	۰,۸۷	۰,۸۳	۰,۵۸	۰,۸۵	۰,۷۱	۶
۰,۹۵	۰,۹۳	۰,۹۵	۰,۹۳	۰,۸۸	۰,۹۵	۰,۸۰	۷
۰,۹۰	۰,۸۶	۰,۸۶	۰,۸۲	۰,۵۸	۰,۷۷	۰,۷۳	دقت
۰,۸۶	۰,۸۱	۰,۸۱	۰,۷۶	۰,۴۷	۰,۷۰	۰,۶۶	کاپا


مقادیر مشخص شده نمایانگر اشتباهات در سطح اعتبار ۵٪ می‌باشند. کلاس‌های ۱-۷ به صورت جاده‌ها، درختان، سقف قرمز، سقف خاکستری، سقف بتنی، گیاهان و پوشش زمینی می‌باشند.




شکل ۵- مقایسه نتایج طبقه‌بندی تصویر مرئی



شکل ۶- مقایسه ماتریس‌های ابهام طبقه‌بندی تصویر مرئی




شکل ۹- مقایسه نتایج ادغام طبقه‌بندی کننده‌ها




شکل ۱۰- مقایسه ماتریس‌های ابهام نتایج ادغام طبقه‌بندی کننده‌ها

با توجه به نتایج ارائه شده در جداول (۷-۸) و اشکال (۹-۱۰)، ادغام طبقه‌بندی کننده‌های مبتنی بر مدل‌های یادگیری ژرف با بهره‌گیری از برتری عملکرد در طبقه‌بندی انفرادی اطلاعات سنجنده‌ی مرئی و یا فراحرارتی، موجب بهبود ۲,۸۱٪ دقت کلی طبقه‌بندی اطلاعات سنجنده‌های چندگانه شده است. علاوه بر این، در مقایسه روش پیشنهادی طبقه‌بندی اطلاعات سنجنده‌های چندگانه با طبقه‌بندی کننده‌های اطلاعات سنجنده‌ی مرئی و یا فراحرارتی، دقت کلی طبقه‌بندی ۷,۵۷٪ و ۲۲,۲۲٪ بهبود یافته است.


به منظور جمع‌بندی نتایج ارائه شده در این بخش، میانگین دقت طبقه‌بندی تخمین‌گرهای بعد ذاتی به همراه روش‌های طبقه‌بندی مورد استفاده، در قالب شکل (۱۱) ارائه شده است. با توجه به این شکل، روش پیشنهادی تمایل به کسب بالاترین شاخص کیفیت طبقه‌بندی را دارا می‌باشد.



شکل ۱۱- میانگین دقت روش‌های: (۱) تخمین بعد و (۲) طبقه‌بندی



شکل ۷- مقایسه نتایج طبقه‌بندی تصویر فراحرارتی



شکل ۸- مقایسه ماتریس‌های ابهام طبقه‌بندی تصویر فراحرارتی

در انتها، مجموعه‌ای از آزمون‌های مقایسه‌ای بین عملکرد ادغام طبقه‌بندی کننده‌های مختلف (مبتنی بر روش‌های بیزین ساده و فضای دانش رفتاری) در طبقه‌بندی اطلاعات سنجنده‌های چندگانه، صورت پذیرفت.

جدول ۷- مقایسه دقت کلی ادغام طبقه‌بندی کننده‌ها

CNN	SAE	SVM	KNN	NB	DA	DT	
NB							
۰,۹۱	۰,۸۷	۰,۸۷	۰,۸۱	۰,۶۹	۰,۸۱	۰,۷۶	EV
		۰,۹۰	۰,۹۰	۰,۸۰	۰,۸۹	۰,۸۲	HS
		۰,۹۱	۰,۹۰	۰,۷۹	۰,۹۰	۰,۸۵	NH
BKS							
۰,۹۷	۰,۸۹	۰,۸۱	۰,۷۶	۰,۶۶	۰,۷۶	۰,۷۶	EV
		۰,۸۹	۰,۹۰	۰,۷۹	۰,۹۰	۰,۸۳	HS
		۰,۹۲	۰,۸۹	۰,۷۷	۰,۹۰	۰,۸۵	NH

جدول ۸- مقایسه دقت ادغام طبقه‌بندی کننده‌ها

	CNN	SAE	SVM	KNN	NB	DA	DT	
۱,۰۰	۰,۹۸	۰,۹۴	۰,۹۴	۰,۹۳	۰,۹۳	۰,۸۸	۰,۸۸	۱
۰,۸۹	۰,۸۴	۰,۸۱	۰,۷۵	۰,۵۲	۰,۷۶	۰,۸۲	۰,۸۲	۲
۰,۹۷	۰,۸۹	۰,۹۴	۰,۹۴	۰,۷۶	۰,۹۲	۰,۸۷	۰,۸۷	۳
۰,۹۶	۰,۷۲	۰,۸۹	۰,۸۵	۰,۴۵	۰,۸۷	۰,۸۴	۰,۸۴	۴
۰,۹۶	۰,۸۲	۰,۹۶	۰,۹۵	۰,۹۴	۰,۹۶	۰,۹۳	۰,۹۳	۵
۰,۹۵	۰,۷۸	۰,۸۷	۰,۸۴	۰,۶۴	۰,۸۴	۰,۷۱	۰,۷۱	۶
۱,۰۰	۰,۹۲	۰,۹۶	۰,۹۴	۰,۹۰	۰,۹۵	۰,۸۸	۰,۸۸	۷
۰,۹۷	۰,۸۹	۰,۹۲	۰,۹۰	۰,۸۰	۰,۹۰	۰,۸۵	۰,۸۵	دقت
۰,۹۶	۰,۸۵	۰,۸۹	۰,۸۷	۰,۷۳	۰,۸۷	۰,۸۰	۰,۸۰	کاپا


مقادیر مشخص شده نمایانگر اشتباهات در سطح اعتبار ۵٪ می‌باشند. کلاس‌های ۱-۷ به صورت جاده‌ها، درختان، سقف قرمز، سقف خاکستری، سقف بتنی، گیاهان و پوشش زمینی می‌باشند.

در ادامه، آنالیز عملکرد طبقه‌بندی کننده‌های مبتنی بر مدل‌های یادگیری ژرف با هدف طبقه‌بندی اطلاعات سنجندهی مرئی و یا فراحتراتی شامل آنالیز زمان اجرایی و تأثیرگذاری عمق بر دقت طبقه‌بندی کننده‌های مبتنی بر مدل‌های یادگیری ژرف بیان شده است. به‌علاوه، زمان اجرایی در طبقه‌بندی کننده‌های مبتنی بر مدل‌های یادگیری ژرف بیانگر زمان آموزش و آزمایش به‌صورت هم‌زمان می‌باشد. در این زمینه، زمان آموزش نشان دهندهی زمان مورد نیاز برای آموزش فیلترهای یادگیری ژرف، طبقه‌بندی و بهینه‌سازی معماری ژرف می‌باشد؛ همانطور که در شکل (۱۲) نشان داده شده است، زمان آموزش نسبت به افزایش تعداد نورون‌های مدل یادگیری ژرف و یا تعداد تکرار لازم جهت بهینه‌سازی معماری آن، به تدریج رشد افزاینده‌ای خواهد داشت. همانطور که در جدول (۹) نیز مشخص می‌باشد، زمان آزمایش با افزایش عمق مدل‌های یادگیری ژرف به تدریج افزایش خواهد یافت. از پارامترهای بسیار تأثیرگذار در عملکرد روش‌های طبقه‌بندی مبتنی بر مدل‌های یادگیری ژرف می‌توان به عمق این مدل‌ها اشاره کرد. به‌صورت کلی، عمق‌های بالاتر در مدل‌های یادگیری ژرف نمایانگر ویژگی‌هایی با سطح جزئیات بیشتر از داده‌های ورودی می‌باشند و از طرف دیگر، با افزایش عمق مدل‌های یادگیری ژرف امکان بیش‌تطابق نمودن مدل طبقه‌بندی وجود خواهد داشت؛ به‌همین دلیل تعیین پارامتر عمق بهینه جهت بکارگیری این ویژگی‌ها، جلوگیری از بیش‌تطابق نمودن مدل طبقه‌بندی کننده و در نظرگیری زمان اجرایی نیازمند به محاسباتی همانند جدول (۹) می‌باشد.

۶- نتیجه‌گیری و پیشنهادات

در این تحقیق، روشی نوین به منظور طبقه‌بندی دقیق اطلاعات سنجنده‌های چندگانه مبتنی بر مدل‌های یادگیری ژرف ارائه گردید. به منظور ارزیابی توانایی روش‌های ارائه شده، نسبت به پیاده‌سازی و بکارگیری آن‌ها در طبقه‌بندی عوارض شهری داده‌های منتشر شده توسط کمیته فنی تلفیق داده‌ها و آنالیز تصاویر جامعه بین‌المللی سنجنش از دور و مهندسی علوم زمین در سال ۲۰۱۴ میلادی، اقدام گردید. در این زمینه، مجموعه‌ای از آزمون‌های مقایسه‌ای نسبت به طبقه‌بندی کننده‌های مرسوم صورت گرفت؛ اهم نتایج ارائه شده به‌صورت زیر می‌باشد:

- طبقه‌بندی عوارض شهری مبتنی بر اطلاعات سنجندهی مرئی، به‌دلیل شباهت اطلاعات طیفی این سنجنده میان عوارضی نظیر جاده‌ای با سقف خاکستری و درختان با گیاهان، منجر به عدم توانمندی تمایز و تشخیص صحیح این عوارض و به پیرو آن کاهش دقت طبقه‌بندی می‌گردد. از سوی دیگر، مواد معدنی سیلیکات بخش عمدهی مواد تشکیل دهندهی سطح زمین و عوارض ساخته به‌دست بشر، قادر به نمایش ویژگی‌های طیفی بنیادینی در گستره مادون‌قرمز با طول‌موج بلند بوده و می‌تواند به منظور افزایش دقت طبقه‌بندی اطلاعات سنجندهی مرئی مورد استفاده قرار گیرد.
- روش‌های طبقه‌بندی مبتنی بر مدل‌های یادگیری ژرف با بکارگیری اطلاعات طیفی-مکانی به‌صورت هم‌زمان و به پیرو آن استخراج ویژگی‌های ژرف از داده‌های ورودی، عملکرد به مراتب بهتری نسبت به طبقه‌بندی کننده‌های مرسوم از خود نشان داده‌اند.
- در مقایسه روش‌های طبقه‌بندی مبتنی بر مدل‌های یادگیری ژرف با طبقه‌بندی کننده‌های مرسوم، دقت کلی طبقه‌بندی اطلاعات سنجندهی مرئی ۳۰۹۱٪، فراحتراتی ۶۶۵٪ و چندگانه ۲۰۸۱٪ بهبود یافته است. به‌علاوه، در نظرگیری وابستگی‌های متقابل بین عوارض در قالب اطلاعات زمینه خارجی و یا قوانین پس‌پردازشی به منظور کاهش و یا حذف خطاهای مرسوم روش‌های طبقه‌بندی پیکسل‌مبنا، موجب بهبود دقت کلی ۲۰۷۱٪ می‌گردد.
- در مقایسه روش پیشنهادی طبقه‌بندی اطلاعات سنجنده‌های چندگانه با طبقه‌بندی کننده‌های اطلاعات سنجندهی مرئی و یا فراحتراتی، دقت کلی طبقه‌بندی ۷۰۵۷٪ و ۲۲۰۲٪ بهبود یافته است.
- زمان آموزش مدل‌های یادگیری ژرف، نسبت به افزایش تعداد نورون‌های این مدل و یا تعداد تکرار لازم جهت بهینه‌سازی معماری آن، به تدریج رشد افزاینده‌ای خواهد داشت.
- عمق‌های بالاتر در مدل‌های یادگیری ژرف نمایانگر ویژگی‌هایی با سطح جزئیات بیشتر از داده‌های ورودی می‌باشند و از طرف دیگر، با افزایش عمق مدل‌های یادگیری ژرف امکان بیش‌تطابق نمودن مدل طبقه‌بندی و همچنین افزایش زمان آزمایش وجود خواهد داشت.



شکل ۱۲- آنالیز زمان آموزش مدل‌های یادگیری ژرف

جدول ۹- آنالیز پارامتر بهینه عمق مدل‌های یادگیری ژرف

فراحرارتی		مرئی		آنالیز عمق	
CNN	SAE	CNN	SAE		
٪۷۳٫۲۴	٪۶۴٫۰۱	٪۸۹٫۰۵	٪۸۱٫۸۶	دقت کلی	لایه ۱
۲۱۵٫۲۶	۱۹٫۵۳	۱۶۰٫۸۲	۳۱٫۸۲	زمان آموزش (ثانیه)	
۲۳٫۳۶	۱٫۲۱	۴۵٫۹۱	۱٫۲۵	زمان آزمایش (ثانیه)	
٪۷۳٫۶۶	٪۶۷٫۰۲	٪۸۹٫۷۲	٪۸۴٫۰۴	دقت کلی	لایه ۲
۲۹۱٫۸۳	۲۶٫۳۵	۱۷۲٫۲۳	۴۵٫۸۱	زمان آموزش (ثانیه)	
۳۳٫۶۶	۱٫۳۹	۴۶٫۰۳	۱٫۲۹	زمان آزمایش (ثانیه)	
٪۷۵٫۰۷	٪۶۸٫۹۵	٪۸۸٫۳۰	٪۸۵٫۹۷	دقت کلی	لایه ۳
۳۶۸٫۱۵	۳۳٫۹۹	۱۹۰٫۵۰	۵۹٫۷۴	زمان آموزش (ثانیه)	
۴۵٫۴۸	۱٫۶۵	۵۰٫۹۹	۱٫۴۹	زمان آزمایش (ثانیه)	

دو بعدی، می‌تواند موجب افزایش کارآمدی این دسته از روش‌های طبقه‌بندی گردد.

- در این تحقیق، شبکه‌های عصبی به منظور طبقه‌بندی تصاویر مرئی و یا فراحرارتی طراحی و پیاده‌سازی گردیده است، طبقه‌بندی دیگر تصاویر متداول سنجش از دور می‌تواند به منظور صحت‌سنجی روش پیشنهادی مورد استفاده قرار گیرد.
- در این تحقیق، مدل معماری شبکه‌های عصبی به منظور طبقه‌بندی تصاویر سنجش از دور طراحی و پیاده‌سازی گردیده است؛ بکارگیری مدل معماری‌های از پیش آموزش دیده نظیر الکسنت [۴۵]، گوگل‌نت [۵۱] و یا رزنت [۵۲] با هدف انتقال یادگیری، و بهینه‌سازی آن‌ها در کاربردهای طبقه‌بندی تصاویر سنجش از دور می‌تواند باعث عدم نیاز به طراحی مجدد و یا حتی آموزش مدل معماری یادگیری ژرف گردد.

اگرچه نتایج حاصل از بکارگیری روش پیشنهادی در این تحقیق بیانگر توانایی آن در زمینه طبقه‌بندی عوارض شهری با استفاده از ادغام اطلاعات سنجنده‌های چندگانه می‌باشد، به منظور افزایش کارایی روش فوق موارد ذیل برای تحقیقات آتی پیشنهاد می‌گردد:

- در این تحقیق، روشی نوین به منظور طبقه‌بندی دقیق عوارض شهری مبتنی بر شبکه‌های عصبی اتوانکدر و کانولوشن ارائه شده است؛ تحقیق بر روی دیگر مدل‌های یادگیری ژرف نظیر ماشین بولتزمن محدود شده می‌تواند به منظور صحت‌سنجی نتایج به‌دست آمده مورد استفاده قرار گیرد.
- در این تحقیق، شبکه‌های عصبی یک‌بعدی به منظور طبقه‌بندی تصاویر فراطیفی مورد استفاده قرار گرفته است؛ استفاده از شبکه‌های عصبی سه‌بعدی با هدف در نظرگیری ساختار اطلاعات مکانی به‌صورت

اطلاعات سنجنده‌های چندگانه به‌عنوان یکی دیگر از زمینه‌های تحقیقات آتی پیشنهاد می‌گردد.

- در این تحقیق، ادغام طبقه‌بندی کننده‌ها در بالاترین سطح ممکن و یا به عبارت دیگر، سطح تصمیم‌گیری صورت گرفته است؛ تحقیق بر روی تلفیق عمیق

مراجع

- [1] F. Tabib Mahmoudi, "Decision Level Fusion Based on Multi Views Object Based Image Analysis for Object Recognition in Urban Areas," Ph.D Dissertation, Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, 2014.
- [2] S. Li, H. Wu, D. Wan, and J. Zhu, "An Effective Feature Selection Method for Hyperspectral Image Classification Based on Genetic Algorithm and Support Vector Machine," Knowledge-Based Systems, vol. 24, no. 1, pp. 40–48, 2011.
- [3] P. Du, S. Liu, J. Xia, and Y. Zhao, "Information Fusion Techniques for Change Detection from Multi-Temporal Remote Sensing Images," Information Fusion, vol. 14, no. 1, pp. 19–27, 2013.
- [4] B. Bigdeli, F. Samadzadegan, and P. Reinartz, "A Multiple SVM System for Classification of Hyperspectral Remote Sensing Data," Journal of the Indian Society of Remote Sensing, vol. 41, no. 4, pp. 763–776, 2013.
- [5] B. Bigdeli, F. Samadzadegan, and P. Reinartz, "A Decision Fusion Method Based on Multiple Support Vector Machine System for Fusion of Hyperspectral and LIDAR Data," International Journal of Image and Data Fusion, vol. 5, no. 3, pp. 196–209, 2014.
- [6] X. Lu, J. Zhang, T. Li, and G. Zhang, "Synergetic Classification of Long-Wave Infrared Hyperspectral and Visible Images," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 8, no. 7, pp. 3546–3557, 2015.
- [7] G. Abdi, F. Samadzadegan, and P. Reinartz, "A Decision-Based Multi-Sensor Classification System using Thermal Hyperspectral and Visible Data in Urban Area," European Journal of Remote Sensing, vol. 50, no. 1, pp. 414–427, 2017.
- [8] J. Li, H. Zhang, M. Guo, L. Zhang, H. Shen, and Q. Du, "Urban Classification by the Fusion of Thermal Infrared Hyperspectral and Visible Data," Photogrammetric Engineering & Remote Sensing, vol. 81, no. 12, pp. 901–911, 2015.
- [9] W. Liao et al., "Processing of Multiresolution Thermal Hyperspectral and Digital Color Data: Outcome of the 2014 IEEE GRSS Data Fusion Contest," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 8, no. 6, pp. 2984–2996, 2015.
- [10] X. Chen, S. Xiang, C.-L. Liu, and C.-H. Pan, "Vehicle Detection in Satellite Images by Hybrid Deep Convolutional Neural Networks," IEEE Geoscience and remote sensing letters, vol. 11, no. 10, pp. 1797–1801, 2014.
- [11] Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, "Deep Learning-Based Classification of Hyperspectral Data," IEEE Journal of Selected topics in applied earth observations and remote sensing, vol. 7, no. 6, pp. 2094–2107, 2014.
- [12] C. Tao, H. Pan, Y. Li, and Z. Zou, "Unsupervised Spectral–Spatial Feature Learning with Stacked Sparse Autoencoder for Hyperspectral Imagery Classification," IEEE Geoscience and remote sensing letters, vol. 12, no. 12, pp. 2438–2442, 2015.
- [13] J. Yue, W. Zhao, S. Mao, and H. Liu, "Spectral–Spatial Classification of Hyperspectral Images using Deep Convolutional Neural Networks," Remote Sensing Letters, vol. 6, no. 6, pp. 468–477, 2015.
- [14] K. Makantasis, K. Karantza, A. Doulamis, and K. Loupos, "Deep Learning-Based Man-Made Object Detection from Hyperspectral Data," in International Symposium on Visual Computing, 2015, pp. 717–727.
- [15] H. Liang and Q. Li, "Hyperspectral Imagery Classification using Sparse Representations of Convolutional Neural Network Features," Remote Sensing, vol. 8, no. 2, p. 99, 2016.
- [16] M. Långkvist, A. Kiselev, M. Alirezaie, and A. Loutfi, "Classification and Segmentation of Satellite Orthoimagery using Convolutional Neural Networks," Remote Sensing, vol. 8, no. 4, p. 329, 2016.
- [17] C. Zhao, X. Wan, G. Zhao, B. Cui, W. Liu, and B. Qi, "Spectral-Spatial Classification of Hyperspectral Imagery Based on Stacked Sparse Autoencoder and Random Forest," European Journal of Remote Sensing, vol. 50, no. 1, pp. 47–63, 2017.

- [18] L. Wang, J. Zhang, P. Liu, K.-K. R. Choo, and F. Huang, "Spectral-Spatial Multi-Feature-Based Deep Learning for Hyperspectral Remote Sensing Image Classification," *Soft Computing*, vol. 21, no. 1, pp. 213–221, 2017.
- [19] S. Yu, S. Jia, and C. Xu, "Convolutional Neural Networks for Hyperspectral Image Classification," *Neurocomputing*, vol. 219, pp. 88–98, 2017.
- [20] P. Ghamisi, J. Plaza, Y. Chen, J. Li, and A. J. Plaza, "Advanced Spectral Classifiers for Hyperspectral Images: A Review," *IEEE Geoscience and Remote Sensing Magazine*, vol. 5, no. 1, pp. 8–32, 2017.
- [21] G. Abdi, F. Samadzadegan, and P. Reinartz, "Spectral-Spatial Feature Learning for Hyperspectral Imagery Classification using Deep Stacked Sparse Autoencoder," *Journal of Applied Remote Sensing*, vol. 11, no. 4, p. 042604, 2017.
- [22] M. Eslami and A. Mohammadzadeh, "Developing a Spectral-Based Strategy for Urban Object Detection from Airborne Hyperspectral TIR and Visible Data," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 5, pp. 1808–1816, 2016.
- [23] F. Samadzadegan, H. Hasani, and P. Reinartz, "Toward Optimum Fusion of Thermal Hyperspectral and Visible Images in Classification of Urban Area," *Photogrammetric Engineering & Remote Sensing*, vol. 83, no. 4, pp. 269–280, 2017.
- [24] M. Eslami and A. Mohammadzadeh, "A Novel Method for Urban Land Cover Mapping Based on New Vegetation Indices and Texture-Spectral Information from Fused Visible and Hyperspectral Thermal Infrared Airborne Data," *European Journal of Remote Sensing*, vol. 50, no. 1, pp. 320–331, 2017.
- [25] C.-H. Li, B.-C. Kuo, C.-T. Lin, and C.-S. Huang, "A Spatial-Contextual Support Vector Machine for Remotely Sensed Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 3, pp. 784–799, 2012.
- [26] L. Fang, S. Li, X. Kang, and J. A. Benediktsson, "Spectral-Spatial Hyperspectral Image Classification via Multiscale Adaptive Sparse Representation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 12, pp. 7738–7749, 2014.
- [27] D. Akbari, S. Homayouni, A. Safari, and N. Mehrshad, "Mapping Urban Land Cover Based on Spatial-Spectral Classification of Hyperspectral Remote-Sensing Data," *International Journal of Remote Sensing*, vol. 37, no. 2, pp. 440–454, 2016.
- [28] C.-I. Chang, *Hyperspectral Data Processing: Algorithm Design and Analysis*. John Wiley & Sons, 2013.
- [29] H. Hasani, "Determination of Optimum Classification System for Hyperspectral Imagery Based on Swarm Intelligence Optimization Algorithms," M.S. Thesis, Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, 2011.
- [30] L. Zhang, L. Zhang, and B. Du, "Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art," *IEEE Geoscience and Remote Sensing Magazine*, vol. 4, no. 2, pp. 22–40, 2016.
- [31] T. Serre, G. Kreiman, M. Kouh, C. Cadieu, U. Knoblich, and T. Poggio, "A quantitative theory of immediate visual recognition," *Progress in brain research*, vol. 165, pp. 33–56, 2007.
- [32] A. Ng, "Sparse autoencoder," *CS294A Lecture notes*, vol. 72, no. 2011, pp. 1–19, 2011.
- [33] K. Karalas, "Sparse representations in machine learning and remote sensing," Master of science, Technical university of Crete, 2015.
- [34] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [35] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [36] S. Muruganandham, *Semantic Segmentation of Satellite Images using Deep Learning*. 2016.
- [37] A. Karpathy, "Cs231n: Convolutional neural networks for visual recognition," *Neural networks*, vol. 1, 2016.
- [38] Y. A. LeCun, L. Bottou, G. B. Orr, and K.-R. Müller, "Efficient backprop," in *Neural networks: Tricks of the trade*, Springer, 2012, pp. 9–48.
- [39] P. Lennie, "The cost of cortical computation," *Current biology*, vol. 13, no. 6, pp. 493–497, 2003.
- [40] P. C. Petrantonis and P. Poirazi, "A compressed sensing perspective of hippocampal function," *Frontiers in systems neuroscience*, vol. 8, 2014.
- [41] Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle, "Greedy layer-wise training of deep networks," in *Advances in neural information processing systems*, 2007, pp. 153–160.
- [42] M. Matsugu, K. Mori, Y. Mitari, and Y. Kaneda, "Subject independent facial expression recognition with robust face detection using a convolutional neural network," *Neural Networks*, vol. 16, no. 5, pp. 555–559, 2003.

- [43] Y. LeCun, "LeNet-5, convolutional neural networks," URL: <http://yann.lecun.com/exdb/lenet>, 2015.
- [44] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, 2012, pp. 1097–1105.
- [45] F. Samadzadegan, F. Tabib Mahmoudi and B. Bigdeli, Data Fusion in Remote Sensing: Concepts and Techniques. University of Tehran Press, 2012.
- [46] C. M. Bishop, Pattern recognition and machine learning. springer, 2006.
- [47] C.-T. Lin and C. G. Lee, "Neural fuzzy systems," PTR Prentice Hall, 1996.
- [48] L. I. Kuncheva, Combining pattern classifiers: methods and algorithms, Second Edition. John Wiley & Sons, 2014.
- [49] Y. S. Huang and C. Y. Suen, "A method of combining multiple experts for the recognition of unconstrained handwritten numerals," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 17, no. 1, pp. 90–94, 1995.
- [50] M. Baatz, "Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation," Angewandte geographische informationsverarbeitung, pp. 12–23, 2000.
- [51] C. Szegedy et al., "Going deeper with convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1–9.
- [52] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks," in European Conference on Computer Vision, 2016, pp. 630–645.