

استخراج دانش از سیستم استنتاج نوروفازی انطباق پذیر جهت شناسایی عوارض خاص شهری (مطالعه موردی: درختان و ساختمان‌ها)

پرهام پهلوانی^{۱*}، حامد امینی امیرکلائی^۲

^۱ استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران
pahlavani@ut.ac.ir

^۲ دانشجوی دکتری فتوگرامتری - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی
دانشگاه تهران
eng.hamedamini.69@gmail.com

(تاریخ دریافت بهمن ۱۳۹۳، تاریخ تصویب آبان ۱۳۹۴)

چکیده

امروزه از سیستم‌های شناسایی قدرتمندی جهت کلاسه‌بندی داده‌ها استفاده می‌شود که روند یادگیری در آن‌ها به‌صورت جعبه‌سیاه بوده بگونه‌ای که نحوه کلاسه‌بندی و ارتباط بین توصیفگرها برای کاربر قابل فهم نمی‌باشند. درحالی‌که قابل فهم بودن دانش بدست آمده توسط سیستم‌های شناسایی می‌تواند کمک شایان توجهی به کاربر نماید تا کلاسه‌بندی را با دقت و صحت بیشتری انجام دهد. ازاین‌رو کشف دانش در قالب استخراج مجموعه‌ای از قوانین جهت کلاسه‌بندی داده‌ها ازجمله موضوعات مهم و پرکاربرد در پردازش تصویر می‌باشد که سبب درک بهتر روش کلاسه‌بندی و بهبود آن در گام‌های بعدی می‌گردد. هدف این مقاله، پیشنهاد روندی جهت استخراج قوانین فازی به‌صورت شرطی از سیستم استنتاج نوروفازی انطباق پذیر برای کلاسه‌بندی داده‌های لیدار و تصاویر هوایی رقومی می‌باشد. تا بدین وسیله میزان اهمیت و ارتباط بین توصیفگرهایی که منجر به استخراج یک عارضه خاص می‌گردند در قالب یکسری قوانین فازی با زبان قابل فهم برای کاربر شناسایی گردند. به بیان دیگر مشخص شود که ارتباط کدامیک از توصیفگرها در شناسایی یک عارضه از بالاترین میزان اهمیت برخوردار است. در این راستا ابتدا تعدادی توصیفگر بالقوه اولیه تولید شده و سپس توصیفگرهای بهینه توسط الگوریتم ژنتیک انتخاب شدند. با وارد نمودن داده‌های آموزشی به الگوریتم جداسازی تورانه‌ای مقادیر اولیه برای مجموعه‌های فازی در مقدم قوانین تعیین گشت و طی فرآیند آموزش، کلاسه‌بندی کننده نهایی ایجاد و دو کلاس درختان و ساختمان‌ها شناسایی گشتند. سپس با پیشنهاد یک روش فازی-مبنا و با استفاده از توابع عضویت نهایی بدست آمده از سیستم استنتاج نوروفازی انطباق پذیر و داده‌های آموزشی اخذشده از لایه‌های توصیفگر، مجموعه قوانین فازی مؤثر از فرآیند شناسایی استخراج گشت. قوانین فازی استخراج شده از این روش از لحاظ منطقی و با در نظر گرفتن لایه‌های توصیفگر مورد بررسی قرار گرفتند که نتایج نشان از توانایی بالای روش پیشنهادی در استخراج قوانین از فرآیند شناسایی داشتند.

واژگان کلیدی: داده‌های لیدار، تصاویر هوایی رقومی، قوانین فازی، سیستم استنتاج نوروفازی انطباق پذیر

* نویسنده‌ی رابط

۱- مقدمه

امروزه الگوریتم‌های متعددی جهت کلاسه‌بندی داده‌ها مطرح می‌باشند که توانایی استخراج دانش از مجموعه‌ای از داده‌ها را دارند، اما انسان قادر به فهم دانش بدست آمده از میان نقطه‌ها و وزن‌ها نمی‌باشد. استخراج قانون به صورت فازی می‌تواند از طرفی به درک عمیق‌تر از الگوریتم شناسایی جهت بررسی منطق داخلی سیستم کمک نماید [۱] و از طرف دیگر می‌تواند به کشف وابستگی‌های جدید داده‌های آموزشی منجر شود [۱]. اصل مهم در استخراج قانون درستی و قابل‌درک بودن قوانین استخراج شده است. درستی به معنای آن است که قوانین استخراج شده بیانگر کلیه اطلاعات و رفتار الگوریتم شناسایی بوده و قابل‌درک بودن به معنای تفسیرپذیری قوانین استخراج شده است [۱]. همچنین با کاهش تعداد قوانین استخراج شده می‌توان به درک بهتر روند کلاسه‌بندی کمک نمود که این کار نیاز به تکنیک‌ها منظم‌سازی نظیر وزن‌دهی و هرس کردن قوانین دارد [۱]. از این‌رو تحقیقات گسترده‌ای جهت استخراج قوانین از الگوریتم‌های مختلف کلاسه‌بندی صورت پذیرفته است. در [۲] از روش مجموعه‌های زبر برای کلاسه‌بندی اطلاعات، استخراج قوانین از آن‌ها و کاهش اطلاعات همپوشان یا تکراری استفاده شد. همچنین در [۳] روندی جهت استخراج قوانین از یک ماشین بردار پشتیبان که فرآیند درونی آن جعبه‌سیاه^۱ مانند است مطرح گشت. در [۴] روشی جهت استخراج قوانین از یک ماشین بردار پشتیبان آموزش دیده به صورت مستقیم بر اساس توصیفگرهای متمایز ارائه شد. همچنین، انتخاب مهم‌ترین توصیفگرها نیز مدنظر قرار گرفت. [۵] بر روی الگوریتم‌های خطی تمرکز کرده و روندی جهت استخراج قانون از ماشین بردار پشتیبان خطی و دیگر ابرصفحه‌های خطی پیشنهاد نمود. استخراج دانش از شبکه‌های عصبی به دلیل آن که فرآیند درونی آن جعبه‌سیاه مانند است، موضوعی پرچالش می‌باشد. در [۶] از یک روند فازی min-max بر اساس شبکه عصبی برای کلاسه‌بندی بهره گرفته شد و سپس با استفاده از الگوریتم ژنتیک قوانین، استخراج گشته و در میان آن‌ها شماری از لایه‌های توصیفگر که اهمیت کمتری

را در شناسایی داشتند، حذف گشتند. در [۷] جهت استخراج دانش برای پیش‌بینی ورشکستگی از الگوریتم عصبی و کلاسه‌بندی باینری استفاده شد تا به قوانینی ساده از شاخص‌های مالی دست یابد. در [۸] با تشکیل یک ساختار ابرمستطیل ترکیبی با شبکه عصبی و نیز استفاده از روش تصمیم‌گیری نظارت‌شده، کلاسه‌بندی اطلاعات انجام شده و قوانین از طریق وزن‌های الگوریتم آموزش دیده، استخراج گشتند. در [۹] روشی جهت استخراج قوانین از شبکه‌های عصبی چندلایه پیش خوراند ارائه داده است. در این روش سعی گشته است تا از آموزش بازگشتی برای ارائه قوانین کمتر و قابل‌درک‌تر بهره گرفته شود. در [۱۰] تمرکز بر روی شبکه‌های عصبی چندلایه پرسپترون با ورودی‌های گسسته است. به طوری که ابتدا یک شبکه عصبی به درستی آموزش داده می‌شود. سپس قوانین متناسب با داده‌های آموزشی به گونه‌ای استخراج می‌گردد که توانایی شبیه‌سازی رفتار شبکه را داشته باشد.

در [۱۱ و ۱۵] از سیستم استنتاج نوروفازی انطباق پذیر^۲ (ANFIS) که از روش‌های قدرتمند هوش محاسباتی جهت کلاسه‌بندی داده‌ها بوده و دارای عملکرد بسیار مناسبی می‌باشد، استفاده شده است. این سیستم از توانایی یادگیری و بهینه‌سازی شبکه عصبی و بیان زبانی استنتاج فازی به صورت همزمان بهره برده است اما روند یادگیری در آن به صورت جعبه‌سیاه عمل می‌نماید. در این راستا، استفاده از الگوریتم جداسازی تورانه‌ای برای ایجاد یک مدل اولیه از نوع سوگنو می‌تواند در کلاسه‌بندی و شناسایی هرچه بهتر داده‌ها مؤثر باشد. زیرا هرچه دقت مدل اولیه بیشتر باشد، دقت قوانین نهایی فازی استخراج شده از سیستم استنتاج نوروفازی انطباق پذیر نیز بیشتر می‌شود. از آنجا که کاربر با قوانین فازی نسبت به قوانین قطعی بهتر ارتباط برقرار می‌کند، در این مقاله سعی شده است تا روندی جهت استخراج قوانین فازی به صورت شرطی ارائه گردد.

داده‌های مربوط به فتوگرامتری و سنجش از دور به دلیل کاربردهای بسیار متنوعی در تهیه نقشه‌های مختلف از سطح زمین جهت برنامه‌ریزی و مدیریت شهری و روستایی دارند. از این‌رو کشف دانش از طریق استخراج

^۲ Adaptive Neuro-Fuzzy System^۱ Black box

میدان تصادفی شرطی استفاده نمود و از داده‌های شدت برای جداسازی دو کلاس ساختمان و درخت از هم بهره برد [۲۲].

هدف این مقاله ارائه روندی جهت استخراج قوانین فازی از سیستم استنتاج نوروفازی انطباق‌پذیر می‌باشد. به‌گونه‌ای که قوانین بدست آمده از فرآیند یادگیری داده‌های آموزشی و به‌روزرسانی پارامترهای خطی و غیرخطی سیستم استنتاج نوروفازی انطباق‌پذیر باشد. بنابراین سعی شده است با استفاده از مقادیر اولیه بدست آمده از الگوریتم جداسازی تورانه‌ای برای مجموعه‌های فازی در مقدم قوانین و تنظیم پارامترهای خطی و غیرخطی توابع عضویت در طول فرآیند آموزش، قوانینی که بیشترین تأثیر را در فرآیند کلاسه‌بندی دارا می‌باشند استخراج نمود. قوانین حاصله به‌صورت گزاره‌های شرطی نمایش داده می‌شوند، به‌گونه‌ای که هم قابل فهم باشند و هم بتوان خطا را در میان آن‌ها شناسایی، تصحیح و یا حذف نمود. همچنین می‌توان از قوانین استخراج‌شده جهت کلاسه‌بندی و شناسایی عوارض مناطق دیگری که لایه‌های توصیفگر یکسانی با لایه‌های توصیفگر این تحقیق داشته باشد استفاده نمود و با تشکیل یک سیستم فازی ساده با دقتی بالا فرآیند کلاسه‌بندی را انجام داد. به این صورت نیاز به اپراتور حرفه‌ای جهت اخذ داده‌های آموزشی دقیق و کارآمد برای آموزش سیستم استنتاج نوروفازی انطباق‌پذیر از بین می‌رود و درعین حال کلاسه‌بندی با دقتی و صحتی بالا صورت می‌پذیرد.


در ادامه ساختار مقاله بدین صورت است که در بخش ۲ روند پیشنهادی شناسایی عوارض و استخراج قوانین شرطی ارائه شده است. در بخش ۳ به پیاده‌سازی روش‌های پیشنهادی در کلاسه‌بندی و شناسایی عوارض و استخراج قوانین پرداخته شده و نتایج مورد ارزیابی و بحث قرار می‌گیرند. در نهایت در بخش ۴، نتایج حاصل‌شده از این مقاله ارائه گشته و پیشنهادات آتی طرح می‌گردد.

۲- روند پیشنهادی

در این بخش ابتدا روند پیشنهادی جهت شناسایی ساختمان‌ها و درختان ارائه شده (بخش ۲-۱) و سپس روند پیشنهادی برای استخراج قوانین فازی به طور کامل

مجموعه‌ای از قوانین شرطی اگر-آنگاه از کلاسه‌بندی داده‌های هوایی و فضایی می‌تواند در زمینه بهبود این فرایند راهگشا باشد. با پیشرفت سنجش‌ازدور، همواره سنجنده‌ها و تجهیزات آن در حال تغییر و به‌روز شدن می‌باشند. در نتیجه روش‌های پردازش و استخراج اطلاعات از آن‌ها نیز همواره در حال تغییر است. لیدار از جمله تکنولوژی‌های نسبتاً جدید برای جمع‌آوری اطلاعات از سطح زمین می‌باشد که با ارسال و دریافت پالس‌های لیزر، به ابر نقطاتی با مختصات سه‌بعدی از محدوده موردبررسی دست می‌یابد. پیشرفت روزافزون فن‌آوری لیدار، دقت بسیار بالایی مسطحاتی و ارتفاعی داده‌های اخذشده آن و همچنین ثبت شدت سیگنال‌های بازگشتی باعث شده است که استفاده از داده‌های لیدار به‌صورت چشم‌گیری افزایش یابد. کلاسه‌بندی داده‌های لیدار به علت کثرت عوارض سه‌بعدی و پیچیدگی روابط میان عوارض همواره دچار مشکل بوده است. از این رو استفاده از تصاویر هوایی رقومی به دلیل قدرت رادیومتریکی بالا در کنار داده‌های لیدار می‌تواند باعث افزایش دقت فرآیند کلاسه‌بندی گردد. تاکنون روش‌ها و الگوریتم‌های متفاوتی جهت کلاسه‌بندی و شناسایی عوارض روی سطح زمین با استفاده از داده‌های لیدار به تنهایی و یا با کمک تصاویر هوایی رقومی و فضایی مطرح گشته است. [۱۶] از تلفیق تصاویر هوایی رقومی و داده‌های لیدار استفاده نمود و ابتدا عوارض مرتفع را شناسایی کرده و سپس با استفاده از NDVI ساختمان‌ها و درخت‌ها را از یکدیگر تفکیک نمود. در [۱۷] از میزان تحذب و همواری برای جداسازی ساختمان‌ها و درختان بهره گرفته شد و برای شناسایی راه‌ها از قاب‌هایی با اندازه و جهت‌های متفاوت استفاده گشت که با اسکن تصویر منطقه توسط این قاب‌ها شبکه کلی راه‌ها استخراج شد. همچنین می‌توان از الگوریتم‌هایی نظیر Hough و RANSAC برای بهبود مرز ساختمان‌ها و بدست آوردن مرز دقیق آن‌ها استفاده نمود [۱۸-۲۰]. الگوریتم‌های آماری نظیر میدان تصادفی مارکف و میدان تصادفی شرطی نیز در طبقه‌بندی مؤثر بوده و عملکرد مناسبی دارند. در [۲۱] برای کلاسه‌بندی توصیف یک مدل میدان تصادفی شرطی برای ابر نقاط نامنظم و استخراج خصوصیات هندسی نظیر دامنه، عرض و تعداد پیکوak موج به‌عنوان داده‌های توصیفگر استفاده شدند. بعلاوه می‌توان از مقادیر ویژه برای استخراج ویژگی‌ها در

شرح داده می‌شود (بخش ۲-۲). در شکل ۱ شمای کلی روند ارائه شده در این مقاله نشان داده شده است.



شکل ۱- روند کلی روند پیشنهادی

۱-۲- کلاسه‌بندی و شناسایی عوارض

در مرحله کلاسه‌بندی، هدف شناسایی عوارض ساختمان‌ها و درختان درون شهری می‌باشد. در این راستا، ابتدا روند انتخاب توصیفگرهای بهینه با استفاده از الگوریتم ژنتیک مطرح می‌گردد (بخش ۱-۲-۱). سپس با استفاده از الگوریتم جداسازی تورانه‌ای و سیستم استنتاج نوروفازی انطباق پذیر به شناسایی درختان و ساختمان‌ها اقدام شده (بخش ۲-۱-۲) و در نهایت روند ارزیابی نتایج شناسایی مطرح شده است (۲-۱-۳).

۱-۱-۲- انتخاب لایه‌های توصیفگر بهینه

شناسایی ساختمان‌ها و درختان درون شهری نیازمند تعیین توصیفگرهایی برای اجرای فرآیند شناسایی می‌باشد. زیرا الگوریتم‌های کلاسه‌بندی با توجه به بردار توصیف هر پیکسل در مورد ماهیت آن تصمیم‌گیری می‌کنند. این توصیفگرها می‌توانند به صورت طیفی، بافتی و یا ساختاری امکان تفکیک اشیاء را فراهم سازند. امروزه با افزایش تعداد سنجنده‌های فعال و غیرفعال امکان ثبت خصوصیات طیفی، بافتی و ساختاری اشیاء در طول موج‌های مختلف و شیوه‌های گوناگون به وجود آمده است. در این مقاله ۱۲ توصیفگر بالقوه که می‌توانند در شناسایی

عوارض مؤثر باشند، تولید شدند. بسیاری از توصیفگرهایی که امکان تولید آن‌ها با استفاده از داده‌های لیدار و تصاویر هوایی وجود دارد، کاربردی در شناسایی ساختمان‌ها ندارند. به همین دلیل، در این تحقیق، از توصیفگرهایی که در تحقیقات گذشته دارای کاربری مناسب بوده و یا به دلیل ساختار و ماهیت هندسی آن‌ها انتظار می‌رفت عملکرد مؤثری در شناسایی داشته باشند، انتخاب شدند.

شاخص‌های گیاهی NDVI [۲۳]، SAVI [۲۴]،^۱ MS-AVI [۲۵] به همراه سه باند فضای رنگی YIQ^۲ [۲۶] با استفاده از تصاویر هوایی رقومی دارای باند مادون قرمز نزدیک ایجاد شدند. از داده‌های فاصله‌سنجی لیدار برای تولید توصیفگرهای شیب [۲۷]، خم پروفیل [۲۷]، خم سطح [۲۷]، مدل رقومی سطحی نرمال شده^۴ (nDSM) [۲۳] و زبری^۵ [۲۶] بهره گرفته می‌شود. داده‌های شدت سیگنال لیدار^۶ (LIP) هم به صورت مستقیم به عنوان توصیفگر استفاده گشت. در جدول ۱ توصیفگرهای مورد استفاده به همراه روابط ریاضی آن‌ها آورده شده‌اند.

پس از ایجاد لایه‌های توصیفگر، هر پیکسل دارای یک بردار ویژگی مطابق رابطه (۱) است.

$$\underline{x}_i = [x_i(1) \ x_i(2) \ \dots \]), \quad (1)$$

که n تعداد لایه‌های توصیفگر و i شماره پیکسل موردنظر می‌باشد. لازم به ذکر است که پس از ایجاد لایه‌های توصیفگر، مقادیر این لایه‌ها مطابق با رابطه (۲) به منظور یکسان‌سازی محدوده لایه‌های توصیفگر به بازه‌ای [0,1] تعیین می‌گردد، تبدیل می‌شوند.

$$x_i^N(j) = \left(\frac{x_i(j) - a_j}{b_j - a_j} \right), \quad \forall j \in \{1, 2, \dots, n\}, \quad (2)$$

که a_j و b_j به ترتیب کمترین و بیشترین مقادیر پیکسل‌های توصیفگر j تولید شده می‌باشند. ساختار کلی داده‌های آموزشی باید به صورت رابطه (۳) باشد.

^۱ Soil Adjusted Vegetation Index (SAVI)

^۲ Modified Soil Adjustment Vegetation

^۳ Modified Soil Adjusted Vegetation Index

^۴ normalized Digital Surface Model

^۵ Roughness

^۶ Last Intensity Pulse

جدول ۱- توصیفگرهای مورد استفاده و روابط ایجاد آنها

No.	Features	Formula
1	NDVI	$NDVI = \frac{NIR - R}{NIR + R}$
2	SAVI	$SAVI = \frac{NIR - R}{NIR + R + L} \times (1 + L)$
3	MSAVI	$L = 1 - \frac{2 \times s \times (NIR - R) \times (NIR - s \times R)}{NIR + R}$ $MSAVI = \frac{(2 \times NIR - \sqrt{(2 \times NIR + 1)^2 - 8 \times (NIR - R)})}{2}$
4	Y (YIQ)	$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ 0.595716 & -0.274453 & -0.321263 \\ 0.211456 & -0.522591 & 0.311135 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}$
5	I (YIQ)	
6	Q (YIQ)	
7	Plane Curvature	$PlaCur = \left(\frac{-(1 + H^2 \times D) + (2 \times G \times H \times F) + (1 + G^2 \times E)}{2 \times (1 + G^2 + H^2)^{3/2}} \right)$ $G = \frac{\partial f}{\partial x}, H = \frac{\partial f}{\partial y}$ $D = \frac{\partial^2 f}{\partial x^2}, E = \frac{\partial^2 f}{\partial y^2}$
8	Profile Curvature	$ProCur = \left(\frac{-(G^2 \times D) + (2 \times G \times H \times F) + (H^2 \times E)}{(G^2 \times H^2) \times (1 + G^2 + H^2)^{3/2}} \right)$ $F = \frac{\partial^2 f}{\partial x \partial y}$
9	Slope	$Slope = \sqrt{G^2 + H^2}$
10	Roughness	$Rough_Max = R_V - z_0, \quad R_V = \max(z_1, z_2, z_3, z_4, z_5, z_6, z_7, z_8, z_9)$
11	nDSM	$nDSM = DSM - DTM$
12	LIP	The last intensity pulse of LiDAR

مختلف فضای جواب جستجو می‌شود. درواقع مطابق مکانیزمی با عنوان توازی ضمنی^۱ جستجو فضا به نواحی‌ای که در آن متوسط آماری تابع هدف بیشتر بوده و امکان وجود نقطه بهینه در آن بیشتر است، سوق پیدا می‌نماید. به‌طور کلی الگوریتم ژنتیک دارای ۵ بخش اصلی شامل رمزگذاری^۲، تابع برازندگی^۳، آمیزش^۴، جهش^۵ و رمزگشایی^۶ می‌باشد [۲۹]. الگوریتم ژنتیک به جای کار بر روی پارامترها بر روی شکل رمزگذاری شده آنها کار می‌نماید. به همین دلیل در الگوریتم ژنتیک استفاده شده، تصویر هر یک از توصیفگرها به صورت یک ستون به عنوان یک کروموزوم فضای جستجو در نظر گرفته می‌شود و به صورت باینری رمزگذاری می‌گردند. مجموعه‌ای از کروموزوم‌ها بک جمعیت را تشکیل می‌دهند که با تأثیر عملگرهای ژنتیکی بر روی جمعیت، جمعیت جدید حاصل می‌شود.

$$TrD = \begin{bmatrix} x_1^N(1) & x_1^N(2) & \cdots & \cdots & 1 & 1 \\ x_2^N(1) & x_2^N(2) & \cdots & \cdots & 1 & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ x_p^N(1) & x_p^N(2) & \cdots & \cdots & 1 & 1 \\ x_{p+1}^N(1) & x_{p+1}^N(2) & \cdots & \cdots & n & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ x_q^N(1) & x_q^N(2) & \cdots & \cdots & 1 & 0 \end{bmatrix}, \quad (3)$$


که TrD ماتریس داده‌های آموزشی برای یک عارضه خاص، q تعداد کل داده‌های آموزشی، p تعداد داده‌های آموزشی عارضه موردنظر و n تعداد لایه‌های توصیفگر می‌باشد. همان‌طور که مشاهده می‌شود، برای شناسایی هر عارضه باید ماتریس داده‌های آموزشی مطابق رابطه (۳) تنظیم گردد. به‌گونه‌ای که پیکسل‌های مربوط به عارضه موردنظر دارای خروجی 1 و پیکسل‌های مربوط به عوارض دیگر دارای خروجی 0 باشند.

در این مقاله، از الگوریتم ژنتیک ارائه‌شده در [۲۹] برای استخراج توصیفگرهای بهینه استفاده گشت. در این الگوریتم با در نظر گرفتن مجموعه‌ای از نقاط فضای جواب در هر تکرار محاسباتی به نحو مؤثری نواحی

^۱ Implicit parallelism^۲ Encoding^۳ Evaluation^۴ Crossover^۵ Mutation^۶ Decoding

الگوریتم جداسازی تورانه‌ای^۵ [۳۰] می‌گردند و با تعیین نوع و تعداد توابع عضویت ورودی و نوع توابع عضویت خروجی، یک سیستم استنتاج فازی^۶ از نوع سوگنو با یک خروجی از مدل ایجاد می‌شود. در الگوریتم جداسازی تورانه‌ای با چک کردن کل حالات ممکن، بهترین حالت برای توابع عضویت استخراج می‌شود. لازم به ذکر است که در انتخاب نوع توابع عضویت خروجی در جداسازی تورانه‌ای از تابع عضویت خطی^۷ استفاده شده است [۳۰].

سپس داده‌های آموزشی و چک وارد سیستم استنتاج نوروفازی انطباق پذیر ایجاد شده می‌شوند. سیستم استنتاج نوروفازی انطباق پذیر از کلاس شبکه‌های چندلایه‌ای پیش خوراند^{۱۳} انطباق پذیر می‌باشد. این سیستم از قابلیت بیان زبانی سیستم استنتاج فازی و توانایی خودآموزی شبکه‌های عصبی به‌طور همزمان بهره می‌برد. در شکل ۲، ساختار یک سیستم استنتاج نوروفازی انطباق پذیر با دو ورودی و یک خروجی و پنج لایه که لایه‌های دوم، سوم و چهارم به‌عنوان لایه‌های پنهان شناخته می‌شوند، نشان داده شده است. برای نمایش نحوه عملکرد گره‌های مختلف از اشکال دایره و مربع استفاده شده است که هر گره مربع شکل یک گره تطبیقی با پارامترهای قابل تنظیم بوده و هر گره دایره‌ای شکل به‌عنوان یک گره ثابت شناخته می‌شود.



شکل ۲- معماری یک شبکه استنتاج نوروفازی انطباقی با ۲ تابع عضویت و ۲ داده ورودی

در لایه اول مقادیر ورودی‌ها با مقادیر توابع عضویت متناظر با خود مقایسه می‌شوند و میزان تطابق هر ورودی با تابع عضویت متناظر با خود به‌عنوان خروجی گره انتخاب می‌گردد. رابطه (۴) تابع عضویت گوسین مربوطه به گره i را نشان می‌دهد [۳۰]

تابع برازندگی میزان کیفیت هر رشته را با یک عدد مشخص می‌نماید. به طوریکه هر چه کیفیت رشته جواب بالاتر باشد، مقدار برازندگی جواب بیشتر است و احتمال مشارکت برای تولید نسل بعدی نیز افزایش می‌باشد. قدم اول در این مقاله شناسایی ساختمان‌ها است، به همین دلیل الگوریتم KNN ($K=1$) و نوع فاصله اقلیدسی با توجه به غیرپارامتریک بودن آن برای محاسبه تابع برازش هر کروموزوم (ترکیبی از توصیفگرها در جدول ۱) استفاده شد. الگوریتم KNN شامل K نمونه آموزشی است و یک عارضه بر اساس رأی اکثریت همسایه‌های آن طبقه‌بندی می‌شود. بدین ترتیب از شاخص دقت کلی (OA)^۱ بدست آمده از شناسایی برای محاسبه میزان برازندگی هر کروموزوم (ترکیبی از توصیفگرها) الگوریتم ژنتیک استفاده گشت.

عملگر آمیزش جهت ترکیب نسل قدیمی کروموزوم‌ها با تابع انتخاب رقابتی با اندازه ۲۲ [۲۹] در راستای ایجاد نسل جدید به کار گرفته می‌شود. درواقع عملگر آمیزش و استفاده از ژن‌های والد برای تولید نسل جدید باعث از بین رفتن پراکندگی با تنوع ژنتیکی جمعیت می‌شود. در این تحقیق از عملگر آمیزش تک نقطه‌ای^۲ [۲۹] استفاده شد. عملگر جهش نیز جواب‌های ممکن دیگری را تولید می‌نماید. این عملگر امکان دارد ژنی را از مجموعه ژن‌ها حذف نموده و با ژنی که تابه‌حال در جمعیت وجود نداشته است، جایگزین نماید. درواقع نوع جهش وابسته به نوع رمزگذاری متفاوت است. در رمزگشایی و پس از یافتن بهترین جواب، عکس عملیات رمزگذاری صورت می‌گیرد تا جواب نهایی حاصل شود. در این تحقیق از عملگر جهش یکنواخت^۴ [۲۹] استفاده شد.

۲-۱-۲- استفاده از سیستم استنتاج نوروفازی انطباق پذیر

سیستم استنتاج نوروفازی انطباق پذیر برای شناسایی دقیق عوارض با استفاده از توصیفگرهای بهینه انتخاب شده از بخش قبل، مورد استفاده قرار می‌گیرد. در این راستا، داده‌های آموزشی تهیه شده (مطابق رابطه (۳)) ابتدا وارد

^۵ Grid partitioning

^۶ Fuzzy Inference System

^۷ Linear

^۱ Overall Accuracy

^۲ Tournament selection (size=2)

^۳ One point crossover

^۴ Uniform mutation

رابطه (۷) توسط روش تخمین کمترین مربعات محاسبه می‌گردند. در گذر بازگشتی^۵، سیگنال‌های خطا، که مشتقات مربع خطا نسبت به هر گره خروجی می‌باشند، از لایه خروجی به لایه ورودی انتشار می‌یابند. در گذر بازگشتی، پارامترهای غیرخطی مقدم (a_i و c_i) در رابطه (۴) توسط الگوریتم‌های نزول گرادینت^۶ به‌روز می‌شوند. الگوریتم آموزشی ترکیبی نیازمند معرفی پارامترهای تعداد دوره‌ها، حد آستانه خطا، اندازه گام‌های اولیه، نرخ کاهش اندازه گام‌ها و نرخ افزایش اندازه گام‌ها می‌باشد [۳۰]. در نهایت برای هر پیکسل یک درجه عضویت که نشان‌دهنده میزان تعلق به کلاس خروجی موردنظر می‌باشد بدست می‌آید و با در نظر گرفتن یک حدآستانه نتایج نهایی شناسایی عارضه مربوطه بدست می‌آید.

۲-۱-۳- ارزیابی نتایج شناسایی عوارض

در این مقاله، برای ارزیابی نتایج شناسایی، از داده‌های مرجع ارائه‌شده توسط ISPRS برای Working Group III/4 استفاده گشت. همچنین، از چهار معیار تمامیت^۷، صحت^۸ و کیفیت^۹ (روابط (۹)، (۱۰) و (۱۱)) و دقت کلی (OA) برای ارزیابی توانایی الگوریتم جداسازی تورانه‌ای و استنتاج نوروفازی انطباق‌پذیر در شناسایی و تفکیک دو کلاس درختان و ساختمان‌ها بهره گرفته شد.

$$Completeness = \frac{TP}{TP + FN}, \quad (9)$$

$$Correctness = \frac{TP}{TP + FP}, \quad (10)$$

$$Quality = \frac{TP}{TP + FP + FN}, \quad (11)$$

به‌گونه‌ای که در این روابط برای پیکسل‌هایی که مورد ارزیابی قرار می‌گیرند TP یا True Positive معرف نقاطی است که به‌طور صحیح شناسایی شده‌اند. FN یا False Negative معرف نقاطی می‌باشد که شناسایی نشده‌اند و در نهایت FP یا False Positive مشخص‌کننده نقاطی می‌باشد که مربوط به کلاس تعیین‌شده نبوده و به‌اشتباه شناسایی شده‌اند.

$$\mu_{A_i}(x) = e^{-\frac{1}{2} \left(\frac{x - c_i}{a_i} \right)^2}, \quad (4)$$

که $\{a_i, c_i\}$ پارامترهای توابع عضویت مربوط به هر یک از متغیرهای ورودی می‌باشد. پارامترهای توابع عضویت در این لایه به‌عنوان پارامترهای مقدم^۱ شناخته می‌شوند [۳۰].

در لایه دوم هر گره به‌عنوان به گره ثابت شناخته می‌شود که خروجی آن حاصل ضرب تمام سیگنال‌های ورودی است (رابطه (۵)) [۳۰].

$$w_i = m_{A_i}(x_1)' m_{B_i}(x_2) \quad i = 1, 2, \quad (5)$$

در لایه سوم به نرمال‌سازی پرداخته شده و هر گره در این لایه یک گره ثابت می‌باشد. همچنین گره i نسبت وزن قانون i به مجموع وزن‌های تمام قانون‌ها را محاسبه می‌نماید (رابطه (۶)) [۳۰].

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2. \quad (6)$$

هر گره i در لایه چهارم یک گره تطبیقی با رابطه (۷) می‌باشد [۳۰].

$$\bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad i = 1, 2, \quad (7)$$

لایه پنجم تنها از یک گره ثابت با عملکرد رابطه (۸) تشکیل شده است که خروجی شبکه (f) را محاسبه می‌نماید [۳۰].

$$f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}. \quad (8)$$

در سیستم استنتاج نوروفازی انطباق‌پذیر از الگوریتم آموزشی ترکیبی^۲ برای تنظیم پارامترهای توابع عضویت بهره گرفته شده است که در آن از روش پس انتشار برای پارامترهای مربوطه به توابع عضویت و از تخمین کمترین مربعات^۳ برای پارامترهای مربوط به توابع عضویت خروجی استفاده شده است [۳۰]. در گذر روبه‌جلو^۴ در الگوریتم یادگیری ترکیبی، پارامترهای خطی تالی (p_i ، q_i و r_i) در

^۵ Backward pass

^۶ Gradient descent

^۷ Completeness

^۸ Correctness

^۹ Quality

^۱ Premise parameters

^۲ Hybrid

^۳ Least Squares Estimation (LSE)

^۴ Forward pass

۲-۲- الگوریتم استخراج قوانین فازی

در این بخش از مقاله، برای اولین بار، الگوریتمی جهت کشف دانش در قالب استخراج مجموعه قوانین فازی مؤثر از فرآیند کلاسه‌بندی عوارض ارائه می‌گردد که شامل سه مرحله می‌باشد:

- در مرحله اول پارامترهای مقدم نهایی تنظیم شده (پس از اتمام آموزش) مربوط به توابع عضویت ورودی‌های سیستم استنتاج نوروفازی انطباق پذیر استخراج گشته و مطابق با میانگین توابع مرتب می‌گردند.

- در مرحله دوم، قانون فازی آتش شده^۱ مربوط به هر داده آموزشی متعلق به یک کلاس عارضه خاص (ساختمان یا درخت) شناسایی می‌شود.

- در مرحله سوم قوانین فازی که بیشترین اهمیت را در فرآیند کلاسه‌بندی داشته‌اند، استخراج می‌گردند.

در مرحله اول ابتدا داده‌های آموزشی مربوط به کلاس موردبررسی برای استخراج قوانین فازی مؤثر در شناسایی آن کلاس خاص، جداسازی می‌گردند. سپس پارامترهای مقدم تنظیم شده توابع عضویت ورودی بدست آمده از آموزش سیستم استنتاج نوروفازی انطباق پذیر استخراج شده و مطابق با میانگین توابع به صورت صعودی مرتب می‌شوند. تعداد کل توابع عضویت تمامی توصیفگرها طبق رابطه زیر محاسبه می‌گردد:

$$nMFs = nMF \times n, \quad (12)$$

که nMF ، تعداد توابع عضویت در لایه اول سیستم استنتاج نوروفازی (شکل ۲) مشخص شده برای هر توصیفگر و n تعداد توصیفگرها می‌باشد.

در مرحله دوم، ابتدا با توجه به تعداد توابع عضویت (nMF) برای هر توصیفگر، تعداد کل قوانین فازی ممکن (NR) از طریق رابطه (۱۳) تعیین می‌گردد. رابطه (۱۴) نشان‌دهنده ماتریس قوانین ایجاد شده است به گونه‌ای که هر ردیف از این ماتریس به یک قانون اشاره دارد. همچنین فاصله میان هر دو خط نقطه‌چین در ماتریس R به یک توصیفگر اشاره دارد. برای هر قانون، در هر ردیف، عدد ۱ مشخص می‌کند که کدام تابع عضویت (ترم فازی) لحاظ شده است. به عنوان مثال، اگر سه توصیفگر ($n=3$) شامل $x^N(1)$ و $x^N(2)$ و $x^N(3)$ و برای هر توصیفگر دو تابع عضویت فازی ($nMF=2$) با برچسب‌های زبانی

کم (L) و زیاد (H) وجود داشته باشد، بر اساس رابطه (۱۳) تعداد کل قوانین فازی ممکن برابر با ۹ قانون شده و ماتریس کل قوانین فازی ممکن برابر با رابطه (۱۵) خواهد بود.

$$NR = nMF^n. \quad (13)$$

$$R = \begin{bmatrix} 1 & 0 & \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & 0 & \dots & \dots & \dots & \dots & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & \dots & \dots & \dots & \dots & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix}, \quad (14)$$

$$R = \begin{array}{c|c|c|c|c|c} L & H & L & H & L & H \\ \hline 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 & 1 & 0 \\ 1 & 0 & 0 & 1 & 0 & 1 \\ 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 0 & 0 & 1 \\ 0 & 1 & 0 & 1 & 1 & 0 \\ 0 & 1 & 0 & 1 & 0 & 1 \end{array}, \quad (15)$$

$\xleftarrow{x^N(1)} \quad \xleftarrow{x^N(2)} \quad \xleftarrow{x^N(3)}$

برای مثال در رابطه (۱۵) قانون ردیف اول می‌تواند به صورت زیر تعریف شود:

IF $x^N(1)$ is L and $x^N(2)$ is L and $x^N(3)$ is L
THEN data i (row i) of Eq. (5) belongs to Class A

اکنون برای هر داده آموزشی (هر ردیف ماتریس رابطه (۳)) میزان آتش برای تمامی قوانین (ردیف‌های) رابطه (۱۴) محاسبه می‌شود تا مشخص گردد برای هر داده آموزشی کدامیک از قوانین بیشترین تأثیر را داشته است. برای این منظور برای هر داده آموزشی ورودی به سیستم استنتاج نوروفازی از رابطه (۳) متعلق به یک عارضه خاص:

$$x_i^N(k), \forall i \in \{1, 2, \dots, p\}, \forall k \in \{1, 2, \dots, n\}$$

مقدار تابع عضویت (رابطه (۴)) تعریف شده برای آن توصیفگر ($\mu_s^k(x_i^N(k))$) که در قانون $r \in NR$ صدا زده شده است محاسبه می‌گردد (رابطه (۱۶)).

^۱ Fired Rule

تعداد ستون‌ها برابر تعداد قوانین (NR) می‌باشد. رابطه (۲۳) نیز میزان اهمیت بدست آمده برای هر قانون را نشان می‌دهد. به عنوان مثال قانون اول (ستون اول ماتریس رابطه (۲۲)) بیشترین مقدار آتش (Fq) را برای چهار داده آموزشی ($Nq = 4$) داشته است. در این صورت، مقدار اهمیت این قانون بر اساس رابطه (۲۱) برابر با 0.26 خواهد شد (رابطه (۲۳) را ببینید).

$$TrR = \begin{bmatrix} 0.54 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0.67 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.68 & 0.75 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.64 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.77 & 0 & 0 \\ 0 & 0 & 0 & 0.57 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.84 & 0 & 0 & 0 & 0 \\ 0.65 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0.74 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}_{p \times NR}$$

$$I_q = [0.26 \ 0 \ 0.068 \ 0.216 \ 0 \ 0.141 \ 0 \ 0]. \quad (23)$$

۳- پیاده‌سازی و ارزیابی نتایج

پیاده‌سازی و ارزیابی نتایج در سه بخش صورت پذیرفته است، در بخش ۳-۱، منطقه مورد مطالعه و داده‌های مورد استفاده شرح داده شده است. در بخش ۳-۲، نتایج کلاسه‌بندی با استفاده از الگوریتم جداسازی تورانه‌ای و سیستم استنتاج نوروفازی انطباق‌پذیر تشریح شده است. بخش ۳-۳ نیز حاوی نتایج حاصل از استخراج قوانین مؤثر مطابق روش پیشنهاد شده (بخش ۲-۲) در این مقاله است.


۳-۱- منطقه مورد مطالعه و داده‌های استفاده شده

داده‌های مورد استفاده برای پیاده‌سازی روش پیشنهادی مربوط به شهر Vaihingen آلمان می‌باشد که توسط انجمن سنجش‌ازدور آلمان^۱ (DGPF) تهیه شده است. این داده‌ها حاوی ۱۰ نوار اسکن هوایی و همچنین

تصاویر هوایی رقومی با سه باند می‌باشند. داده‌های اسکن دارای همپوشانی حداکثر ۳۰ درصد بوده و تراکم نقاط تا ۶ یا ۷ نقطه در هر مترمربع در مناطق همپوشانی می‌باشد، ولی در مناطقی که در یک نوار حضور دارند تراکم ۴ نقطه در هر مترمربع است. داده‌های اسکن حاوی داده‌های شدت سیگنال بازگشتی از سطح زمین نیز می‌باشند. تصاویر هوایی رقومی منطقه شامل سه باند سبز، قرمز و مادون قرمز نزدیک بوده و دارای قدرت تفکیک مکانی ۸ سانتی‌متر و قدرت تفکیک رادیومتریکی ۱۱ بیت می‌باشند. این داده‌ها در سه ناحیه در اختیار کاربران قرار گرفته‌اند که هر یک از نواحی دارای خصوصیات منحصربه‌فردی می‌باشند.

- ناحیه ۱ حاوی ساختمان‌های قدیمی با سقف‌هایی پیچیده به همراه تعدادی درخت می‌باشد.
- ناحیه ۲ دارای ساختمان‌های بلندی است که توسط درختان احاطه شده است.




- ناحیه ۳ کاملاً مسکونی بوده و حاوی خانه‌های مستقل و کوچک نیز می‌باشد. شکل ۳ تصاویر هوایی رقومی سه ناحیه مورد بررسی و محدوده تعیین شده هر یک توسط ISPRS را نشان می‌دهد.



شکل ۳- ناحیه‌های مورد مطالعه و محدوده بررسی آن‌ها، (الف) ناحیه ۱، (ب) ناحیه ۲ و (ج) ناحیه ۳

^۱ German Society for Photogrammetry, Remote Sensing and Geoinformation

"کم"، "متوسط" و "زیاد" در بیان قوانین بهره گرفته شود. شکل ۴ توصیفگرهای بهینه هر یک از نواحی را نشان می‌دهد.

	LIP	nDSM	NDVI	
Area 1				
	LIP	nDSM	NDVI	Slope
Area 2				
	LIP	nDSM	MSAVI	Slope
Area 3				

شکل ۴- توصیفگرهای بهینه انتخاب‌شده برای هر یک از نواحی

تنظیمات اولیه پارامترهای الگوریتم آموزش ترکیبی موردنیاز سیستم استنتاج نوروفازی انطباق‌پذیر شامل تعداد دوره‌ها، حد آستانه خطا، اندازه گام اولیه، نرخ کاهش اندازه گام و نرخ افزایش اندازه گام به ترتیب مطابق با جدول ۴ تنظیم گشتند.

جدول ۴- مقادیر اولیه پارامترهای مورد استفاده در سیستم استنتاج نوروفازی انطباق‌پذیر

Initial parameters	Value
Training epoch number	300
Error tolerance	0
Initial step size	0.1
Step size increase rate	1.1
Step size decrease rate	0.9

روند آموزش ترکیبی سیستم استنتاج نوروفازی انطباق‌پذیر پذیر تا زمان رسیدن خطا به حد مطلوب خود و یا رسیدن سیستم استنتاج نوروفازی به حداکثر تعداد دوره تعیین‌شده ادامه می‌یابد. غالباً اندازه گام‌های آموزشی در روند آموزش ابتدا افزایش می‌یابد و پس از رسیدن به مقدار بیشینه تا انتهای فرآیند کاهش می‌یابد. به این صورت که اگر در ۴ تکرار متوالی خطا کاهش یابد، اندازه گام‌ها با ضرب شدن در نرخ افزایش گام‌ها که مقداری ثابت و بزرگ‌تر از ۱ است، افزایش می‌یابد. اما در صورتی که مقدار خطا در ۲ تکرار

۳-۲- کلاسه‌بندی و شناسایی عوارض

برای شناسایی درختان و ساختمان‌ها ابتدا لایه‌های توصیفگر برای هر سه ناحیه مورد مطالعه ایجاد گشته و مقادیر هر سه لایه توصیفگر ارائه‌شده در بخش ۲-۱-۱ از طریق رابطه (۲) نرمال شده و به محدوده [0,1] تبدیل شدند. در این فرایند از ۱٪ از داده‌های مرجع به‌عنوان داده‌های آموزشی و از ۱۰۰٪ داده‌ها جهت تست بهره گرفته شده است (بخش ۲-۱). تعداد داده‌های آموزشی مورد استفاده در هر ناحیه در جدول ۲ نشان داده شده است.

جدول ۲- تعداد داده‌های آموزشی مورد استفاده در هر ناحیه جهت شناسایی درختان و ساختمان‌ها

Objects	Area 1	Area 2	Area 3
Tree	74	82	68
non Tree	461	386	663
Building	208	164	290
non_Building	327	304	441

بر اساس الگوریتم ژنتیک مورد استفاده [۲۹] تعداد تکرار نسل ۵۰ مرتبه، میزان جمعیت اولیه ۵۰، تعداد نخبه^۱ قابل انتقال به نسل بعد ۱، احتمال جهش ۰/۰۱ با تابع جهش یکنواخت^۲، احتمال آمیزش ۰/۸ با تابع آمیزش تک نقطه‌ای^۳، نسبت مهاجرت^۴ ۰/۲، فاصله مهاجرت^۵ ۲۰ و میزان جمع شدگی^۶ ۰/۷ در نظر گرفته شد. الگوریتم ژنتیک با رسیدن به دقت کلی ۸۰٪ در ناحیه ۱، ۸۳٪ در ناحیه ۲ و ۸۲٪ در ناحیه ۳ توصیفگرهای بهینه را انتخاب نمود. جدول ۳ توصیفگرهای بهینه انتخاب شده در هر ناحیه را نشان می‌دهد.

جدول ۳- توصیفگرهای بهینه انتخاب‌شده

Test areas	Optimal features
Area 1	NDVI - nDSM - LIP
Area 2	NDVI - nDSM - LIP- Slope
Area 3	MSAVI - nDSM - LIP- Slope

داده‌های آموزشی ابتدا وارد الگوریتم جداسازی تورانه‌ای می‌گردند تا با در نظر گرفتن ۳ تابع عضویت از نوع گوسین (رابطه (۴)) یک مدل استنتاج فازی اولیه ایجاد گردد. در نظر گرفتن سه تابع عضویت سبب می‌گردد از سه مفهوم زبانی

^۱ Elite


^۲ Uniform mutation

^۳ One point crossover


^۴ Migration Fraction

^۵ Migration Interval

^۶ Shrink



(الف)




(ب)

شکل ۷- روند کلی تغییر اندازه گام‌ها و مقادیر خطای داده‌های آموزشی و چک ناحیه ۳، (الف) درختان، (ب) ساختمان‌ها



(ب)

(الف)




(ج)

شکل ۸- نمایش شماتیک نتایج ارزیابی شناسایی درختان. (الف) ناحیه ۱، (ب) ناحیه ۲، (ج) ناحیه ۳ (زرد: TP، قرمز: FP، آبی: FN)



(ب)

(الف)




(ج)


شکل ۹- نمایش شماتیک نتایج ارزیابی شناسایی ساختمان‌ها. (الف) ناحیه ۱، (ب) ناحیه ۲، (ج) ناحیه ۳ (زرد: TP، قرمز: FP، آبی: FN)

پیاپی نوسان داشته باشد، اندازه گام‌ها در نرخ کاهش گام‌ها که مقداری ثابت و کوچک‌تر از ۱ است، ضرب گشته و کاهش می‌یابد. در شکل‌های ۵، ۶ و ۷ روند کلی تغییر اندازه گام‌ها تا رسیدن به حداکثر تعداد دوره‌ها و همچنین نمودار مربوط به مقادیر خطای داده‌های آموزش و خطای داده‌های چک در هر گام برای هر ناحیه آورده شده است.

در این مقاله، حد آستانه برای تعلق یک پیکسل به کلاس خروجی ساختمان‌ها یا درختان 0.5 در نظر گرفته شد. نتایج بدست آمده با محاسبه پارامترهای تمامیت (Com)، صحت (Cor)، کیفیت (Qu) و دقت کلی (OA) ارائه شده در بخش ۲-۳، از طریق مقایسه نتایج سیستم استنتاج نوروفازی انطباق پذیر با داده‌های مرجع، در جدول ۵ به صورت عددی و در شکل‌های ۸ و ۹ به صورت شماتیک آورده شده است.




(الف)




(ب)

شکل ۵- روند کلی تغییر اندازه گام‌ها و مقادیر خطای داده‌های آموزشی و چک ناحیه ۱، (الف) درختان، (ب) ساختمان‌ها



(الف)



(ب)




شکل ۶- روند کلی تغییر اندازه گام‌ها و مقادیر خطای داده‌های آموزشی و چک ناحیه ۲، (الف) درختان، (ب) ساختمان‌ها

ISPRS در برخی مناطق و نقص آن در شناسایی برخی مناطق نظیر نمایش منظم درختان در داده‌های مرجع در صورتی که درختان دارای ماهیت نامنظمی می‌باشند - از دیگر دلایل دقت نسبتاً پایین در شناسایی درختان است.

دقت نسبتاً پایین شناسایی درختان ناشی از کاراً نبودن توصیفگرها در برخی مناطق جهت تفکیک عوارض می‌باشد مانند ناموفق بودن شاخص NDVI در جهت برآورده کردن انتظارات موردنظر در مناطق سایه که باعث شده است شناسایی در این مناطق دچار مشکل گردد. همچنین درست نبودن داده مرجع ارائه شده توسط

جدول ۵- نتایج ارزیابی پارامترهای تمامیت، صحت و کیفیت

Test area	Object	TP (pixel)	FP (pixel)	FN (pixel)	Com(%)	Cor (%)	Qu (%)	OA (%)
Area 1	Tree	19866	8399	10250	65.96	70.28	51.58	82.45%
	building	98243	12338	6896	93.44	88.84	83.63	
Area 2	Tree	57943	28541	9621	85.76	69.41	62.23	85.67%
	building	73994	14584	2874	96.26	83.54	80.91	
Area 3	Tree	30668	11328	15007	67.14	73.03	53.80	84.41%
	building	123152	25659	7379	94.35	82.76	78.85	



شکل ۱۰- قوانین فازی استخراج شده برای هر یک از نواحی، (الف) ناحیه ۱، (ب) ناحیه ۲، (ج) ناحیه ۳

۳-۳- استخراج قوانین مؤثر فازی

در این مرحله پس از شناسایی ساختمان‌ها و درختان، بر اساس روند پیشنهادشده در بخش ۱-۲ و با استفاده از توابع عضویت نهایی بدست آمده از سیستم استنتاج نوروفازی انطباق‌پذیر، قوانین فازی مؤثر به صورت قوانین شرطی اگر - آنگاه استخراج می‌گردند. نمودارهای نشان داده شده در شکل ۱۰، قوانین فازی استخراج شده از فرآیند کلاسه بندی را به همراه میزان اهمیت هر یک از آن‌ها نشان می‌دهد.

حد آستانه میزان اهمیت برای استخراج قوانین مؤثر 0.04 در نظر گرفته شد. جداول ۶ و ۷ قوانین فازی مؤثر مطابق با روند پیشنهادی را نشان می‌دهد. در این جداول ستون دوم (r) مربوط به شماره قانون فازی مؤثر از میان مجموعه قوانین فازی ممکن در هر ناحیه می‌باشد. در ستون سوم (*Rules*) قانون فازی استخراج شده به صورت کامل ذکر شده است و در ستون چهارم (*Importance*) نیز میزان اهمیت قانون ذکر شده بر اساس رابطه (۲۱)، بیان گردیده است.

جدول ۶- قوانین دارای میزان اهمیت بیشتر از 0.04 برای شناسایی درختان در هر یک از نواحی

No.	r	Rules	Importance
Area 1			
1	18	If LIP is medium and NDVI is high and nDSM is high, then it is a Tree.	0.42247
2	17	If LIP is medium and NDVI is high and nDSM is medium, then it is a Tree.	0.11825
3	26	If LIP is high and NDVI is high and nDSM is medium, then it is a Tree.	0.09944
4	9	If LIP is low and NDVI is high and nDSM is high, then it is a Tree.	0.06198
Area 2			
1	18	If LIP is high and NDVI is medium and nDSM is medium and Slope is medium, then it is a Tree.	0.32574
2	17	If LIP is medium and NDVI is high and nDSM is high and Slope is medium, then it is a Tree.	0.15892
3	14	If LIP is medium and NDVI is high and nDSM is medium and Slope is medium, then it is a Tree.	0.08420
4	9	If LIP is medium and NDVI is medium and nDSM is medium and Slope is high, then it is a Tree.	0.08362
5	23	If LIP is low and NDVI is high and nDSM is high and Slope is high, then it is a Tree.	0.07183
Area 3			
1	6	If LIP is low and MSAVI is medium and nDSM is high and Slope is high, then it is a Tree.	0.20044
2	18	If LIP is medium and MSAVI is high and nDSM is high and Slope is medium, then it is a Tree.	0.10966
3	17	If LIP is medium and MSAVI is high and nDSM is medium and Slope is medium, then it is a Tree.	0.07720
4	15	If LIP is medium and MSAVI is medium and nDSM is high and Slope is high, then it is a Tree.	0.07554
5	27	If LIP is high and MSAVI is high and nDSM is high and Slope is low, then it is a Tree.	0.04621


جدول ۷- قوانین دارای میزان اهمیت بیشتر از 0.04 برای ساختمان‌ها درختان در هر یک از نواحی

No.	r	Rules	Importance
Area 1			
1	12	If LIP is medium and NDVI is low and nDSM is high, then it is a Building.	0.40436
Area 2			
1	2	If LIP is low and NDVI is low and nDSM is medium and Slope is high, then it is a Building.	0.16987
2	3	If LIP is low and NDVI is low and nDSM is high and Slope is medium, then it is a Building.	0.16376
3	5	If LIP is low and NDVI is medium and nDSM is medium and Slope is medium, then it is a Building.	0.07364
4	12	If LIP is medium and NDVI is low and nDSM is high and Slope is low, then it is a Building.	0.05981
5	6	If LIP is low and NDVI is medium and nDSM is high and Slope is low, then it is a Building.	0.04671
Area 3			
1	2	If LIP is low and MSAVI is low and nDSM is medium and Slope is medium, then it is a Building.	0.43492
2	11	If LIP is medium and MSAVI is low and nDSM is medium and Slope is low, then it is a Building.	0.14204
3	12	If LIP is medium and MSAVI is low and nDSM is high and Slope is low, then it is a Building.	0.05976

درختان در هر یک از آن‌ها متفاوت می‌باشد. از این رو توصیف‌گرهای بهینه انتخاب شده برای هر یک از نواحی و به تبع آن قوانین فازی استخراج شده متفاوت می‌باشند. همان‌طور که پیش‌تر نیز ذکر شد، قوانین استخراج شده باید هم قابل درک باشند و هم صحت داشته باشند. از آنجاکه قوانین استخراج شده فازی بوده و به صورت شرطی بیان شده‌اند، انسان به راحتی می‌تواند با آن‌ها ارتباط برقرار کرده و درک نماید. علاوه بر این میزان اهمیت هر یک از قوانین نیز مشخص شده است و می‌توان به راحتی متوجه شد که کدام قوانین در شناسایی عارضه مورد نظر مؤثرتر می‌باشند. در صورتی که قانونی در مجموعه قوانین استخراج شده وجود داشته باشد که از لحاظ منطقی اشتباه باشد؛ بدان معناست که داده‌های آموزشی حاوی خطا می‌باشند. بنابراین بررسی منطقی قوانین استخراج شده مطابق عملکرد توصیف‌گرها می‌تواند به اخذ صحیح داده

با توجه به آنکه با اجرای الگوریتم بهینه‌سازی در ناحیه ۱ مطالعاتی سه توصیف‌گر بهینه و در نواحی ۲ و ۳، چهار توصیف‌گر بهینه انتخاب شدند. در نتیجه مطابق رابطه (۱۳) و با توجه به در نظر گرفتن ۳ تابع عضویت برای هر توصیف‌گر، تعداد کل قوانین ممکن برای ناحیه ۱، ۸۱ قانون و برای نواحی ۲ و ۳، ۲۴۳ قانون ایجاد شده است. همان‌طور که در جداول ۶ و ۷ کاملاً مشهود است، از میان کل حالت ممکن برای قوانین در هر ناحیه (۸۱ قانون در ناحیه ۱ و ۲۴۳ قانون در نواحی ۲ و ۳) تنها تعداد محدودی برای شناسایی درختان و ساختمان‌ها استخراج شده است. این بدان معناست که با استفاده از این تعداد قوانین فازی استخراج شده و ایجاد یک سیستم استنتاج فازی می‌توان درختان و ساختمان‌ها را به راحتی و با سرعت و دقتی بالایی شناسایی نمود.

هر یک از نواحی مورد بررسی دارای ویژگی‌های ساختاری منحصربه‌فرد خویش بوده و نوع، ارتفاع و تراکم ساختمان‌ها و



شکل ۱۱- بررسی خطاهای شناسایی درختان با توجه به قوانین استخراج شده

همان‌طور که دیده شد، با توجه به قوانین استخراج شده می‌توان علت کاهش خطا در روند شناسایی را متوجه شد که یا از انتخاب داده‌های آموزشی می‌باشد و یا مربوط به ناتوانی توصیفگرها در برآورده نمودن تمام انتظارات است. همچنین قوانین استخراج شده بیانگر رابطه مابین توصیفگرها جهت شناسایی عوارض مختلف می‌باشند که این عامل می‌تواند برای کاربران بسیار کارآمد باشد. میزان Importance بدست آمده برای قوانین نیز میزان اهمیت رابطه موجود بین توصیفگرها در قانون

آموزشی کمک نماید. به‌طور مثال درختان عوارضی با مقدار شاخص گیاهی زیاد می‌باشند و این امر کاملاً در قوانین استخراج شده رعایت شده است. همچنین درختان و ساختمان‌ها عوارضی دارای ارتفاع می‌باشند و توصیفگر nDSM نشان‌گر میزان ارتفاع عوارض است. بررسی قوانین استخراج شده نیز نشان می‌دهد که هیچ‌یک از قوانین دارای مقادیر کم nDSM نمی‌باشند. در نتیجه قوانین استخراج شده از لحاظ منطقی صحیح بوده و این به معنای انتخاب صحیح داده‌های آموزشی است.

در ادامه برخی دلایل عدم شناسایی و یا شناسایی اشتباه درختان و ساختمان‌ها بررسی می‌شود. همان‌طور که گفته شد، در قوانین استخراج شده مقادیر شاخص گیاهی (NDVI یا MSAVI) برای گیاهان هیچ‌گاه کم (low) نبوده است (جداول ۶ و ۷). باین‌حال در برخی مناطق، گیاهان به‌اشتباه به‌عنوان ساختمان شناسایی شده‌اند (شکل ۱۱). با بررسی نتایج مشخص می‌شود که در مناطقی که سایه وجود دارد به علت عدم عملکرد مناسب شاخص‌های گیاهی، درختان به‌عنوان ساختمان شناسایی شده‌اند (شکل‌های ۱۱-الف و ۱۱-ب). مورد دیگر مربوط به توصیفگر nDSM است. همان‌طور که در قوانین استخراج شده (جداول ۶ و ۷) قابل مشاهده است، nDSM در مورد درختان هیچ‌گاه مقداری کمی ندارد. اما با بررسی برخی درختانی که شناسایی نشده‌اند می‌توان فهمید که اختلال در شناسایی به علت عدم توانایی nDSM در شناسایی تمام عوارض دارای ارتفاع از سطح زمین می‌باشد (شکل ۱۱-ج). این مشکل برای ساختمان‌ها به‌صورت عدم استخراج قسمتی از یک بلوک به‌عنوان عارضه غیرزمینی در nDSM رخ می‌دهد (شکل ۱۱-د).

ذکرشده را نشان می‌دهد. به‌طور کلی کاربر با کسب اطلاع از موارد ذکرشده می‌تواند روند شناسایی را با دقت بیشتر و خطای کمتر انجام دهد.

۴- نتیجه‌گیری

در این مقاله روندی فازی-مبنا جهت استخراج قوانین فازی مؤثر از سیستم استنتاج نوروفازی انطباق‌پذیر پیشنهاد شد. از روند ارائه‌شده برای استخراج قوانین شناسایی ساختمان‌ها و درختان از داده‌های لیدار و تصاویر هوایی رقومی استفاده شد. به همین دلیل ابتدا ۱۲ توصیفگر بالقوه که انتظار می‌رفت در شناسایی مؤثر باشند، تولید شده و سپس توصیفگرهای بهینه با استفاده از الگوریتم ژنتیک شناسایی شدند. در مرحله بعد، شناسایی با استفاده از سیستم استنتاج نوروفازی انطباق‌پذیر صورت پذیرفت. سپس با استفاده از توابع عضویت نهایی بدست آمده از آموزش سیستم استنتاج نوروفازی انطباق‌پذیر و داده‌های آموزشی، قوانین فازی مؤثر در شناسایی استخراج

شدند. بررسی‌ها نشان داد که قوانین فازی استخراج‌شده از لحاظ منطقی کاملاً صحیح بوده و مطابق با واقعیت می‌باشند و این نشان از قدرت بالا و عملکرد مناسب الگوریتم پیشنهادی می‌باشد. قوانین فازی به‌صورت شرطی (اگر - آنگاه) بسیار ساده و قابل‌فهم می‌باشند و به‌راحتی می‌توانند توسط کاربر مورد بررسی و تحلیل قرار گیرند. درواقع دو اصل مهم درستی و قابل‌درک بودن قوانین به‌طور کامل توسط روند پیشنهادی حاصل شد.

با در اختیار داشتن این قوانین فازی و پی بردن به دانش بدست آمده توسط سیستم استنتاج نوروفازی انطباق‌پذیر و همچنین اهمیت و روابط میان توصیفگرها می‌توان شناسایی را با دقت و صحتی بالا انجام داد. در ادامه توصیه می‌گردد، از این روش برای استخراج قوانین فازی مؤثر جهت کلاسه‌بندی تصاویر ماهواره‌ای و رادار اخذشده از سنسورهای مختلف با ویژگی‌های متفاوت استفاده گردد.

مراجع

- [1] Yaochu, J. (2003). Advanced fuzzy systems design and applications. Vol. 112. Springer.
- [2] Wu, Q. and Pan, X. (2011). A Novel Remote Sensing Classification Rule Extraction Method Based on Discrete Rough Set", Eighth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD).
- [3] Chen, Z., Hou, J., Zhang, D., and Qin, X. (2012). An Annotation Rule Extraction Algorithm For Image Retrieval", Contents lists available at SciVerse ScienceDirect. 33, 1257-1268.
- [4] Barakat, N. H., and Bradley, A. P. (2007). Rule extraction from support vector machines: A sequential covering approach. Knowledge and Data Engineering, IEEE Transactions on 19.6, 729-741.
- [5] Glenn, F., Sandilya, S., and Rao, R. B. (2005). Rule extraction from linear support vector machines. Proceedings of the eleventh ACM SIGKDD international conference on Knowledge discovery in data mining. ACM.
- [6] Quteishat, A. and Lim, C.P. (2008). A Modified Fuzzy min-max Neural Network with Rule Extraction and its Application to Fault Detection and Classification", Applied Soft Computing. 8, 985-995.
- [7] Lu, J., Tokinaga, S., Ikeda, Y. (2006). Explanatory Rule Extraction Bases on the Trained Neural Network and the Genetic Programming", Journal of the Operations Research Society of Japan, Vol. 49, No. 1, 66-82.
- [8] Su, M-C., Huang, D-Y., Chen, J-H., Lu, W-Z., Tsai, L-C., and Lin, J-Z. (2011). Mapping multi-spectral remote sensing images using rule extraction approach, Expert Systems with Applications. 38, 12917-12922.
- [9] Huynh, Thuan Q. (2009). Improving rule extraction from neural networks by modifying hidden layer representations. Neural Networks, International Joint Conference on. IEEE,.
- [10] Chorowski, Jan., and Zurada, J. M. (2011) "Extracting rules from neural networks as decision diagrams. Neural Networks, IEEE Transactions on 22.12, 2435-2446.
- [11] Sabzevari, R., Masoumzadeh, S., and Ghahroudi, M.R. (2008). Employing ANFIS for Object Detection in Robo-Pong, CSREA Press, pp. 707-712.

- [12] Turkmen, I. (2011). Efficient impulse noise detection method with ANFIS for accurate image restoration, *Aeu-international Journal of Electronics and Communications - AEU-INT J ELECTRON COMMUN*; 65(2):132-139.
- [13] Saxena, S., Kumar, S., and Kumar Sharma, V. (2013). Edge Detection Using Soft Computing in Matlab, *International Journal of Advanced Research in Computer Science and Software Engineering*. Volume 3, Issue 6, ISSN: 2277 128X.
- [14] Sharma, M. (2012). Artificial Neural Network Fuzzy Inference System (ANFIS) For Brain Tumor Detection, *CoRR abs/1212.0059*.
- [15] Bhardwaj, K., and Singh Mann, P. (2013). Adaptive Neuro-Fuzzy Inference System (ANFIS) Based Edge Detection Technique". *International Journal for Science and Emerging Technologies with Latest Trends* 8(1): 7-13, ISSN No. (Print): 2277-8136 ISSN No. (Online): 2250-3641.
- [16] Moussa, A. and El-Shemy., N. (2012). A New Object Based Method For Automated Extraction of Urban Object from Airborne Sensors Data, *XXII ISPRS Congress at Melbourne, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol.XXXIX, Part B3, Melbourn, Australia.
- [17] Zhao, J. and You, S. (2012). Road Network Extraction from Airborne LiDAR Data using Scene Context, *IEEE Computer Society Conference on, Conference Publications*, University of Southern California, Los Angeles, CA 90089.
- [18] Chen, D. and Zhang, L. (2012). Urban building roof segmentation from airborne lidar point clouds, *International Journal of Remote Sensing* 33(20): 6497-6515.
- [19] Tarsha-Kurdi, F. and Landes, T. (2008). Extended RANSAC algorithm for automatic detection of building roof planes from LiDAR data, *The photogrammetric journal of Finland* 21(1): 97-109, 2008.
- [20] Vosselman, G., and Dijkman., S. (2001). 3D building model reconstruction from point clouds and ground plans", *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3/W4, Vol. 34, Annapolis, MA, USA, pp. 37-44, 2001.
- [21] Niemeyer, J., Mallet, C., Rottensteiner, F., Sörgel, U. (2012). Conditional Random Fields for the Classification of LIDAR Point Clouds, *XXII ISPRS Congress at Melbourne, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume I-3, Melbourne, Australia, 2012.
- [22] Niemeyer, J., Rottensteiner, F., Soergel, U. (2013). Classification of Urban LiDAR data using Conditional Random Field and Random Forests, *Proceedings of São Paulo – Brazil*.
- [23] Kriegler, F.J., Maliha, W.A., Nalepka, R.F., and Richardson, W. (1969). Preprocessing transformations and their effects on multispectral recognition, *Proceedings of the Sixth International Symposium on Remote Sensing of Environment*, p. 97-131.
- [24] Richardson, A.J. and J.H. Everitt. (1992). Using spectral vegetation indices to estimate rangeland productivity. *Geocarto International* 7(1):63-69.
- [25] Qi J., Chehbouni A., Huete A.R., Kerr Y.H. (1994). Modified Soil Adjusted Vegetation Index (MSAVI). *Remote Sens Environ* 48:119-126.
- [26] Gonzalez, R.C, Eugene Woods, R, (2008). *Digital image processing*, ISBN number 9780131687288, Publisher: Prentice Hall.
- [27] Zhilin, Li. and aZhu, Q. (2005). *Digital Terrain Modeling: Principles and Methodology*, CRC Press. Boca Raton.
- [28] Arefi, H., and Hahn, M. (2005). A morphological reconstruction algorithm for separating off-terrain points from terrain points in laser scanning data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36.
- [29] Hasanlou, M., Samadzadegan, F. (2011). ICA/PCA base genetically band selection for classification of Hyperspectral images, *31st Asian Conference on Remote Sensing*.
- [30] Jang, J.S.R., Sun, C.T., Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, USA.