

بهبود طبقه‌بندی منطقه شهری با استفاده از داده پلاریمتری راداری و روش‌های بهینه‌سازی

چندهدفه

مریم صالحی^۱، یاسر مقصودی^۲، محمودرضا صاحبی^{۳*}

۱- دانشجوی کارشناسی ارشد، ۲و۳- استادیار، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه‌نصیرالدین طوسی

(دریافت: ۹۲/۰۳/۲۱، پذیرش: ۹۲/۰۹/۲۲)

چکیده

طبقه‌بندی پوشش زمین به‌ویژه در مناطق شهری یکی از مهم‌ترین کاربردهای تصاویر پلاریمتری راداری محسوب می‌شود. به‌منظور استفاده از پتانسیل بالای اطلاعاتی این تصاویر، ویژگی‌های متعددی را می‌توان از آنها استخراج کرد، بنابراین، انتخاب ویژگی نقش مهمی در طبقه‌بندی این تصاویر ایفا می‌کند. در این تحقیق، سه گام اساسی در بهبود طبقه‌بندی اتخاذ شده است: ۱- استخراج ویژگی در قالب سه گروه ویژگی‌های داده اصلی، ویژگی‌های تجزیه هدف، و تفکیک‌کننده‌های SAR؛ ۲- انتخاب حداقل تعداد ویژگی‌ها برای رسیدن به دقت طبقه‌بندی بالا و ۳- طبقه‌بندی با استفاده از ویژگی‌های انتخابی بهینه. در روش‌های پیشنهادی الگوریتم بهینه‌سازی چندهدفه NSGA-II به‌عنوان ابزار جستجو و دو طبقه‌بندی‌کننده ماشین بردار پشتیبان (SVM) و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) در مرحله ارزیابی استفاده شده‌اند. نتایج پیاده‌سازی بر روی تصویر رادارست ۲ منطقه سانفرانسیسکو حاکی از کارایی برتر الگوریتم‌های پیشنهادی در بهبود طبقه‌بندی نسبت به سایر روش‌های مورد استفاده در این تحقیق می‌باشد.

واژگان کلیدی

داده پلاریمتری، انتخاب ویژگی، طبقه‌بندی، بهینه‌سازی چندهدفه، ماشین بردار پشتیبان، سیستم استنتاج عصبی-فازی تطبیقی

۱. مقدمه

فضایبرد سنجش از دور فعال هستند که از سنجنده SAR جهت تولید تصاویر استفاده کرده‌اند. بن^۲ و همکاران [۱] نشان دادند داده رادارست ۱ پتانسیل خوبی برای تهیه نقشه پوشش زمین در منطقه شهری دارد، اما تنها حاوی اطلاعات پلاریزاسیون HH می‌باشد. با پرتاب ماهواره رادارست ۲ در سال ۲۰۰۷، امکان تولید داده‌های پلاریمتری برای این مجموعه ماهواره‌ها نیز فراهم گشت. رادارست ۲ یکی از پیشرفته‌ترین ماهواره‌های تجاری باند C است که می‌تواند تصاویر پلاریمتری شامل هر چهار مد HH، VH، HV و VV را دریافت کند.

داده‌های پلاریمتری به‌دلیل داشتن خصوصیات امواج میکروویو و

فراهم کردن اطلاعات پوشش زمین دقیق و به‌هنگام، در مدیریت شهرها از اهمیت فوق‌العاده بالایی برخوردار است. سنجش از دور SAR^۱ به‌عنوان یکی از روش‌های نوین با قابلیت امکان تصویربرداری در شرایط مختلف آب و هوایی و در طول شبانه‌روز می‌تواند مدیریت شهری را در کسب اطلاعات دقیق و مناسب یاری دهد. ظهور سیستم‌های SAR فضایبرد با رزولوشن بالا امکان استخراج اطلاعات جزئی را از پوشش زمین در مناطق شهری، فراهم آورده است. مجموعه ماهواره‌های رادارست از جمله اولین سری ماهواره‌های

*رایانامه نویسنده پاسخگو: sahebi@kntu.ac.ir

¹ Synthetic Aperture Radar

² Ban

ویژگی‌های تصاویر پلاریمتری SAR تاکنون بررسی نشده است، در این تحقیق برای انتخاب حداقل تعداد ویژگی‌های بهینه و رسیدن به یک مدل طبقه‌بندی با دقت بالا و پیچیدگی محاسباتی پائین، الگوریتم‌های ترکیبی از روش بهینه‌سازی چندهدفه مبتنی بر الگوریتم ژنتیک و طبقه‌بندی‌کننده‌های غیرپارامتریک پیشنهاد شده است. همچنین از آنجا که در اغلب تحقیقات انجام شده از SVM به‌عنوان طبقه‌بندی‌کننده استفاده شده و تاکنون سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)^۳ به‌منظور انتخاب ویژگی و طبقه‌بندی تصاویر SAR به‌کار گرفته نشده است، به بررسی کارایی و عملکرد آنها نیز پرداخته خواهد شد. الگوریتم‌های عصبی- فازی با قابلیت انعطاف‌پذیری بالا عدم قطعیت موجود در داده‌ها را نیز در تصمیم‌گیری نهایی مدنظر قرار می‌دهند که این یک ویژگی مهم به‌ویژه در مورد تصاویر سنجنش از دوری محسوب می‌شود.

در بخش دوم این تحقیق، ویژگی‌های پلاریمتری به‌طور کلی معرفی می‌شود. روش‌های انتخاب ویژگی چندهدفه تحت عنوان MOGA-SVM^۴ و MOGA-ANFIS^۵ و همچنین روش‌های مینا در بخش سوم شرح داده می‌شود. در بخش چهارم الگوریتم‌ها برای انتخاب ویژگی و طبقه‌بندی داده پلاریمتری مورد استفاده قرار می‌گیرند و نتایج آنها بررسی می‌گردد و در نهایت در بخش پنجم نتیجه‌گیری این پژوهش ارائه خواهد شد.

۲. ویژگی‌های پلاریمتری SAR

ویژگی‌های حاصل از تصاویر پلاریمتری را می‌توان به سه دسته تقسیم کرد [۶] که عبارت‌اند از ۱- ویژگی‌هایی که به‌طور مستقیم از داده اصلی به‌دست می‌آیند، ۲- ویژگی‌های حاصل از الگوریتم‌های تجزیه هدف و ۳- تفکیک‌کننده‌های SAR^۵.

۲-۱. ویژگی‌های اصلی

اساسی‌ترین منبع اطلاعاتی سیستم‌های پلاریمتر، ماتریس پراکندگی^۶ [S] می‌باشد که المان‌های آن را اعداد مختلط تشکیل می‌دهند و به‌صورت رابطه (۱) بیان می‌شود.

$$[S] = \begin{pmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{pmatrix} \quad (1)$$

در بسیاری از کاربردهای سنجنش از دور راداری، در صورت منطبق بودن آنتن‌های فرستنده و گیرنده، ماتریس پراکندگی را متقارن در نظر می‌گیرند به‌طوری که S_{vh} و S_{hv} برابر خواهند بود [۸]. این

دارا بودن اطلاعاتی به‌مراتب بیشتر نسبت به داده‌های معمولی SAR نقش مهمی را در کاربردهای مختلف سنجنش از دور مانند طبقه‌بندی پوشش زمین ایفا کرده‌اند. ایجاد سیستم‌های کاملاً پلاریمتریک علاوه بر آنکه منجر به افزایش میزان اطلاعات به‌دست آمده از سنسورهای SAR شده است، پیچیدگی آنالیز و تفسیر داده را نیز بیشتر کرده است. به‌منظور استفاده از داده‌های پلاریمتری، ویژگی‌های متعددی را می‌توان از آنها استخراج کرد. اگرچه هر یک از ویژگی‌های پلاریمتری می‌تواند اطلاعات مناسبی را درباره عوارض مختلف فراهم کند، ولی هیچ‌یک به تنهایی برای توصیف کامل یک عارضه، کافی نمی‌باشد. از طرفی به‌علت وجود ویژگی‌های اضافی و وابسته، استفاده از تمامی ویژگی‌های استخراج شده عملاً منجر به کاهش کارایی طبقه‌بندی می‌شود. تاکنون روش‌های مختلفی برای انتخاب ویژگی و طبقه‌بندی تصاویر PoISAR ارائه شده است [۴-۲]، اما تحقیقات کمی در این زمینه با استفاده از تصویر رادارست ۲ وجود دارد. Qi و همکاران [۵] در آنالیزی شی‌گرا ۶۶ ویژگی از این تصاویر را برای طبقه‌بندی پوشش و کاربری زمین به‌کار بردند. نتایج آنها حاکی از افزایش دقت طبقه‌بندی نسبت به روش‌های رایج طبقه‌بندی مانند نزدیکترین همسایه بود. مقصودی و همکاران [۶] روش‌های انتخاب ویژگی غیرپارامتریک و کلاس مینا را، به‌منظور انتخاب ویژگی از ۵۸ پارامتر اولیه در طبقه‌بندی جنگل پیشنهاد کردند. آنها نشان دادند که انتخاب ویژگی دقت طبقه‌بندی را در مقایسه با طبقه‌بندی‌کننده ویشارت و ماشین بردار پشتیبان^۱ با مجموعه ویژگی کامل به‌طور قابل توجهی بهبود می‌دهد. در این تحقیق، به‌علت پیچیدگی محیط شهری به بررسی پتانسیل داده رادارست ۲ در طبقه‌بندی منطقه شهری سانفرانسیسکو پرداخته شده است.

روش‌های انتخاب ویژگی را می‌توان براساس تابع ارزیابی به دو دسته فیلتر مینا و پوششی^۲ تقسیم کرد [۷]. فیلترها معیارهای مبتنی بر فاصله را به‌عنوان تابع ارزیابی در نظر می‌گیرند. در این روش‌ها انتخاب ویژگی مستقل از عملکرد طبقه‌بندی‌کننده انجام می‌گیرد و با وجود سرعت بالا، ممکن است زیرمجموعه ویژگی بهینه حاصل نشود. روش‌های پوششی دقت طبقه‌بندی را به‌عنوان معیار عملکرد هر زیرمجموعه ویژگی در نظر می‌گیرند. در این روش‌ها با وجود دقت بالا، پیچیدگی و هزینه محاسباتی بیشتر از دسته اول می‌باشد. از طرف دیگر، هدف از انتخاب ویژگی فراهم کردن حداقل تعداد ویژگی‌های مناسب برای رسیدن به عملکرد طبقه‌بندی مشابه یا حتی بهتر در مقایسه با به‌کارگیری تمام ویژگی‌ها می‌باشد. با توجه به این که به‌کارگیری روش‌های بهینه‌سازی چندهدفه در تعیین بهترین

^۳ Adaptive Neuro Fuzzy Inference System

^۴ Multiobjective Genetic Algorithm

^۵ SAR Discriminators

^۶ Scattering Matrix

^۱ Support Vector Machine (SVM)

^۲ Wrapper

مانند جنگل و زمین‌های کشاورزی را بهتر توصیف می‌کنند.

۲-۳. تفکیک‌کننده‌های SAR

کمیت‌های مختلفی از داده SAR به‌عنوان شاخص برای تمییز انواع سطوح یا پوشش‌های زمین استخراج شده است. از جمله این تفکیک‌کننده‌ها می‌توان به توان کل، پلاریزاسیون کسری^۴، حداکثر و حداقل درجه پلاریزاسیون، حداکثر و حداقل شدت کل پراکنده شده و ضرایب وابستگی اشاره کرد. ۱۰۵ ویژگی استفاده شده در این تحقیق در جدول ۱ ارائه شده است. برای اطلاعات بیشتر درباره ویژگی‌های پلاریمتری به مرجع [۶ و ۱۱] مراجعه شود.

۳. روش‌ها

با توجه به شکل ۱، در ابتدا پیش‌پردازش داده پلاریمتری شامل فیلتر کردن اسپکل^۵ و استخراج ویژگی انجام می‌گیرد. مرحله بعد انتخاب بهترین ویژگی‌ها، به‌منظور طبقه‌بندی پوشش زمین می‌باشد. فرآیند انتخاب ویژگی، به‌طور کلی شامل دو مرحله جستجو و ارزیابی است. روش‌های متاهوریستیک^۶ مانند الگوریتم ژنتیک، به‌طور رایج برای جستجوی بهترین زیرمجموعه ویژگی به‌کار گرفته شده‌اند [۱۲]. معمولاً الگوریتم‌های انتخاب ویژگی، تنها دقت طبقه‌بندی را به‌عنوان تابع هدف و معیار ارزیابی هر زیرمجموعه ویژگی در نظر می‌گیرند و تعیین ویژگی‌های بهینه در قالب یک مسئله بهینه‌سازی تک‌هدفه انجام می‌گیرد. در مسائل تک‌هدفه، مقدار حداقل یا حداکثر یک تابع هدف، کیفیت پاسخ به‌دست آمده را به‌طور کامل منعکس می‌کند. اما در برخی موارد لازم است که چندین تابع هدف تعریف شده و به‌طور همزمان مقدار بهینه آنها تعیین شود. در ایجاد یک مدل طبقه‌بندی مناسب علاوه بر دقت، لازم است همزمان معیارهایی مانند پیچیدگی مدل نیز در نظر گرفته شود. یک مدل با عملکرد تعمیم دهی بالا و خطای طبقه‌بندی پائین معمولاً بهترین انتخاب نیست، به‌ویژه اگر یک مدل بسیار پیچیده از نظر محاسباتی داشته باشیم [۱۳]. در این تحقیق به‌منظور حداکثر سازی دقت و حداقل سازی تعداد ویژگی‌های PoISAR انتخابی، دو روش MOGA-SVM و MOGA-ANFIS پیشنهاد شده است که در این روش‌ها، در مرحله جستجو از الگوریتم بهینه‌سازی چندهدفه NSGA-II^۷ استفاده شده و تعداد ویژگی‌های انتخابی و دقت کلی طبقه‌بندی با SVM و یا ANFIS به‌عنوان توابع هدف در نظر گرفته می‌شود.

ماتریس اطلاعات جامعی را در مورد عارضه هدف در اختیار کاربران قرار می‌دهد که با آنالیز آن می‌توان ویژگی‌های مختلفی را استخراج نمود. ویژگی‌های حاصل از دو ماتریس کواریانس ([C]) و همبستگی^۱ ([T]) که بر اساس آنالیز آماری مرتبه دوم ماتریس پراکنده‌گی حاصل می‌شود نیز به‌عنوان ویژگی‌های اصلی استفاده می‌شوند. با در نظر گرفتن بردار هدف k_c حاوی المان‌های ماتریس پراکنده‌گی و بردار هدف k_t حاوی پارامترهای پائولی، این دو ماتریس از رابطه (۲) و (۳) به‌دست می‌آیند.

$$k_c = [S_{hh} \quad \sqrt{2}S_{hv}S_{vv}]^T, [C] = \langle k_c, k_c^{*T} \rangle \quad (2)$$

$$k_t = \frac{1}{\sqrt{2}} [S_{hh} + S_{vv} \quad S_{hh} - S_{vv} \quad 2S_{hv}]^T$$

$$, [T] = \langle k_t, k_t^{*T} \rangle \quad (3)$$

در این روابط، علامت «...» نشان‌دهنده میانگین‌گیری مکانی، و علائم «*» و «T» به ترتیب نشانگر مزدوج مختلط و ترانپوز می‌باشد. از آنجا که المانهای قطری ماتریس کواریانس به‌عنوان ویژگی‌های ماتریس پراکنده‌گی به‌کار گرفته می‌شوند، تنها دامنه و فاز ۳ المان بالامثلثی ماتریس کواریانس در این مطالعه استفاده شده است. همچنین دامنه ۵ المان قطری و بالامثلثی و فاز ۳ المان بالامثلثی ماتریس همبستگی از دیگر ویژگی‌های اصلی می‌باشد. لازم به‌ذکر است از آنجا که سومین المان قطری از ماتریس همبستگی ([T]₃₃) دو برابر دومین المان قطری ماتریس کواریانس ([C]₂₂) می‌باشد، این ویژگی در نظر گرفته نشده است [۶].

۲-۲. ویژگی‌های تجزیه هدف

الگوریتم‌های تجزیه هدف به تفسیر فرآیند پراکنش و اطلاعات فیزیکی موجود در مشاهدات پراکنشی مرتبط با سطوح مختلف کمک می‌کنند. بر مبنای نوع ماتریسی که در تجزیه استفاده می‌شود، می‌توان این الگوریتم‌ها را به دو دسته همدوس^۲ و ناهمدوس^۳ تقسیم کرد [۹]. ویژگی‌های تجزیه هدف همدوس مانند پارامترهای تجزیه Krogager [۱۰]، بر اساس ماتریس پراکنده‌گی و ویژگی‌های تجزیه هدف ناهمدوس بر اساس ماتریس‌های همبستگی یا کواریانس می‌باشند. ویژگی‌های هر دو دسته، به نحوی مکانیزم‌های پراکنده‌گی را توصیف می‌کنند و می‌توانند نقش مکملی در شناسایی اهداف طبیعی و عوارض ساخت بشر داشته باشند. به‌طور کلی روش‌های تجزیه همدوس برای عوارض ساخت بشر مانند ساختمان، جاده و راه آهن مناسب هستند، در حالی که روش‌های ناهمدوس، عوارض طبیعی

⁴ Fractional Polarization

⁵ Speckle

⁶ Metaheuristic

⁷ Non-Dominated Sorting Genetic Algorithm-II

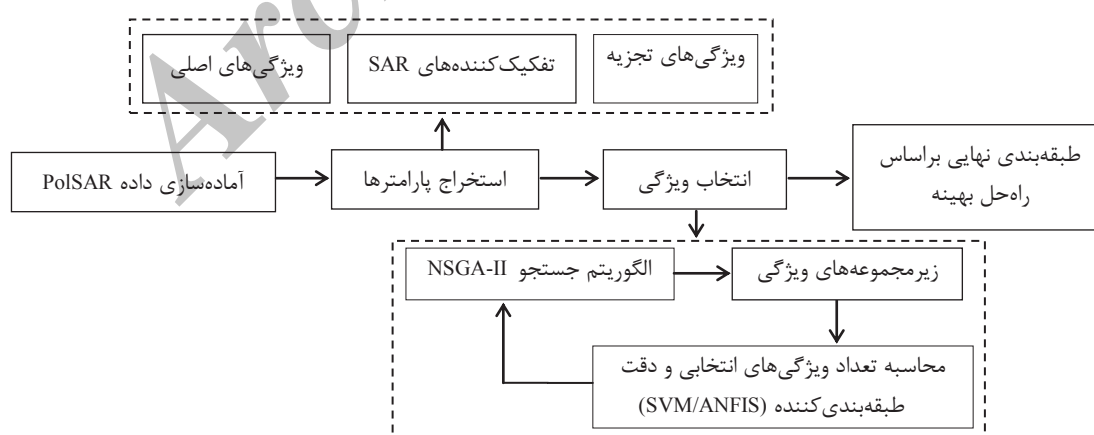
¹ Coherency

² Coherent

³ Incoherent

جدول ۱. ویژگی‌های پلاریمتری مورد استفاده در این تحقیق

ویژگی	توصیف	نماد	تعداد	
ویژگی‌های اصلی	scattering matrix elements	[S]	۳	
	coherency matrix elements	[T]	۸	
	covariance matrix elements	[C]	۶	
ویژگی‌های تجزیه	Krogager	[Krog]	۳	
	Huynen	[Huy]	۹	
	Barnes	[Bar]	۹	
	Cloude	[Clou]	۹	
	Holm	[Holm]	۹	
	Van Zyl	[Vanzyl]	۳	
	Cloude-Pottier	H, A, alpha, beta, lambda, gamma, delta, asym, H_shannon, A_luen, A12, HA, (1-H)A, H(1-A), (1-H)(1-A), ped, SERD, DERD, RVI		۱۹
	Freeman-Durden	[Free]	۳	
	Yamaguchi	[Yama]	۴	
	Touzi	[Touzi]	۴	
تفکیک‌کننده‌های SAR	SPAN	SPAN	۱	
	received power extrema	[pow]	۲	
	fractional polarization	fract	۱	
	degree of polarization extrema	[dop]	۲	
	scattered intensity extrema	[scat]	۲	
	polarized intensity extrema	[pol]	۲	
	unpolarized intensity extrema	[unpol]	۱	
	correlation coefficients	CCC, Ro12, Ro13, Ro23	۴	
	coefficient of variation	V	۱	

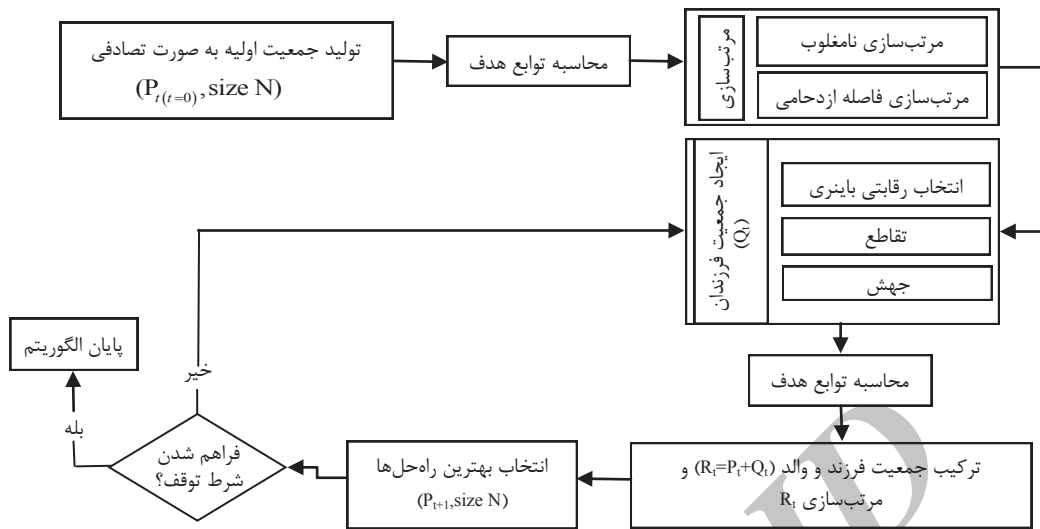


شکل ۱. شمای کلی الگوریتم MOGA-SVM/ANFIS به منظور طبقه‌بندی تصویر PolSAR

تکاملی جایگاه ویژه‌ای دارند. الگوریتم بهینه‌سازی ژنتیک با مرتب‌سازی نامغلوب ۲ (NSGA-II) که توسط Deb و همکارانش در سال ۲۰۰۲ [۱۴] معرفی گردید، یکی از پرکاربردترین و قدرتمندترین

۳-۱. الگوریتم ژنتیک با مرتب‌سازی نامغلوب II

تاکسون روش‌های متعددی برای حل مسائل بهینه‌سازی چندهدفه معرفی شده‌اند که از میان آنها، روش‌های بهینه‌سازی



شکل ۲. فلوچارت الگوریتم NSGA-II

در f^{\max} ، f^{\min} به ترتیب کمترین و بیشترین مقدار تابع هدف در جبهه F است. در ادامه با استفاده از روش انتخاب رقابتی باینری دو راه‌حل به تصادف از میان جمعیت انتخاب شده و میان این دو جواب، مقایسه‌ای انجام می‌شود و هر کدام که بهتر باشد، در نهایت برگزیده می‌شود. معیارهای انتخاب در الگوریتم NSGA-II در درجه اول، رتبه جواب و در درجه دوم، مربوط به فاصله ازدحامی جواب است. هر چه رتبه جواب کمتر باشد و دارای فاصله ازدحامی بیشتری باشد، مطلوب‌تر است.

با تکرار عملگر انتخاب باینری بر روی جمعیت هر نسل، مجموعه‌ای از افراد آن نسل برای شرکت در تقاطع^۳ و جهش^۴ انتخاب می‌شوند و جمعیتی از فرزندان ایجاد می‌شود. در ادامه، این جمعیت با جمعیت اصلی ادغام می‌شود. اعضای جمعیت جدید، ابتدا بر حسب رتبه و به صورت صعودی مرتب می‌شوند و سپس اعضای از جمعیت که دارای رتبه یکسانی هستند، بر حسب فاصله ازدحامی و به صورت نزولی مرتب می‌شوند. حال اعضای جمعیت در درجه اول بر حسب رتبه، و در درجه دوم بر حسب فاصله ازدحامی مرتب‌سازی شده‌اند. برابر با تعداد افراد جمعیت اصلی، اعضای از بالای فهرست مرتب شده انتخاب می‌شوند و بقیه اعضای جمعیت کنار گذاشته می‌شوند. اعضای انتخاب شده جمعیت نسل بعدی را تشکیل می‌دهند و چرخه مذکور در این بخش، تا محقق شدن شرایط خاتمه، تکرار می‌شود. جواب‌های نامغلوب به دست آمده از حل مسئله بهینه‌سازی چندهدفه، غالباً به نام جبهه پارتو^۵ شناخته می‌شوند. هیچ‌کدام از جواب‌های جبهه پارتو بر دیگری ارجحیت ندارند و می‌توان هر کدام را به عنوان یک تصمیم بهینه در نظر گرفت.

الگوریتم‌های موجود برای حل مسائل بهینه‌سازی چندهدفه می‌باشد و کارایی آن در حل مسائل مختلف به اثبات رسیده است. فلوچارت کلی این الگوریتم در شکل ۲ ارائه شده است.

در الگوریتم NSGA-II ابتدا جمعیت اولیه به صورت تصادفی تشکیل می‌شود و مقادیر توابع هدف، یعنی تعداد ویژگی‌های انتخابی و دقت کلی طبقه‌بندی، برای هر راه‌حل محاسبه می‌گردد. سپس اعضای جمعیت در داخل جبهه‌هایی^۱ قرار می‌گیرند، به گونه‌ای که اعضای موجود در جبهه اول (F_1)، یک مجموعه کاملاً نامغلوب از نظر توابع هدف توسط دیگر اعضای جمعیت فعلی می‌باشند. اعضای موجود در F_2 نیز بر همین مبنا تنها توسط اعضای F_1 مغلوب شده و این روند به همین صورت در جبهه‌های دیگر ادامه یافته تا به تمام اعضای موجود در هر جبهه، یک رتبه بر مبنای شماره آن اختصاص داده شود. سپس برای هر عضو در هر جبهه، معیار فاصله ازدحامی^۲ محاسبه می‌شود، به این صورت که ابتدا برای هر تابع هدف نتایج مرتب می‌شود. به نقاطی که حداکثر و حداقل مقدار این تابع هدف را دارند، مقدار فاصله بینهایت اختصاص می‌یابد. فاصله ازدحامی برای سایر اعضای جمعیت در هر جبهه طبق روابط زیر محاسبه می‌شود.

$$cd_1^i = |f_1^{i+1} - f_1^{i-1}| / (f_1^{\max} - f_1^{\min}) \quad (4)$$

$$cd_2^i = |f_2^{i+1} - f_2^{i-1}| / (f_2^{\max} - f_2^{\min}) \quad (5)$$

$$cd(i) = cd_1^i + cd_2^i \quad (6)$$

که در آن $cd(i)$ ، فاصله ازدحامی عضو i ام بر روی جبهه F ، f_1^i و f_2^i به ترتیب مقادیر تابع هدف اول و دوم در i امین عضو در جبهه F و

³ Crossover
⁴ Mutation
⁵ Pareto Front

¹ Front
² Crowding distance

۳-۲. ماشین بردار پشتیبان

تاکنون مطالعات زیادی نشان داده‌اند که طبقه‌بندی با ماشین‌های بردار پشتیبان (SVMs) ارائه شده توسط Vapnik [۱۵]، می‌تواند از سایر روش‌های طبقه‌بندی غیرپارامتریک مانند شبکه‌های عصبی پرسپترون چندلایه (MLP)^۱ و همچنین روش‌های پارامتریک مانند طبقه‌بندی‌کننده حداکثر احتمال دقیق‌تر باشد [۱۶-۱۸]. SVM توزیع آماری خاصی برای داده فرض نمی‌کند و از آنجا که داده سنجش از دور و به‌طور خاص پارامترهای پلاریمتری معمولاً توزیع آماری معلومی ندارد این یک ویژگی مهم محسوب می‌شود، همچنین در مواردی که پارامترها ناهمگن هستند عملکرد خوبی از خود نشان داده است [۱۳].

ایده اصلی ماشین‌های بردار پشتیبان یافتن ابرصفحه بهینه برای جدا کردن دو کلاس با بیشترین حاشیه جداسازی می‌باشد. برای داده غیر قابل تفکیک به صورت خطی، SVM از طریق تابع کرنل فضای ورودی را به یک فضای ویژگی با ابعاد بالاتر که در آن یک فوق صفحه خطی یافت می‌شود، نگاشت می‌کند [۱۹]. در صورت استفاده از توابع کرنل تابع تصمیم‌گیری SVM را می‌توان با رابطه (۷) بیان کرد.

$$f(x) = \sum_{i=1}^N y_i \alpha_i k(x, x_i) + b \quad (7)$$

که در آن $x_i \in \mathbb{R}^d$, $i = 1, \dots, N$ ابعاد ویژگی‌ها، N تعداد نمونه‌های آموزشی مربوط به دو کلاس، $\alpha_i, y_i \in \{-1, +1\}$ ضرایب لاگرانژ و $k(x, x_i)$ تابع کرنل و b ضریب بایاس می‌باشد. از متداول‌ترین توابع کرنل مورد استفاده می‌توان به کرنل چندجمله‌ای، سیگموئیدی و توابع پایه شعاعی اشاره کرد. هر یک از این کرنل‌ها بسته به مسئله مورد نظر می‌توانند نقاط قوت و ضعف خاص خود را داشته باشند.

برای استفاده از SVM در حالت چندکلاسه دو استراتژی یک در برابر بقیه (OAA)^۲ و یک در برابر یک (OAO)^۳ وجود دارد. در روش یک در برابر یک، برای هر زوج کلاس ممکن، از یک SVM باینری استفاده می‌شود، بنابراین، برای C کلاس، $c(c-1)/2$ طبقه‌بندی‌کننده باینری خواهیم داشت. در روش یک در برابر بقیه هر ماشین بردار پشتیبان، داده‌های یک کلاس را از داده‌های کلاس‌های دیگر جدا می‌کند. در این روش برای C کلاس، C طبقه‌بندی‌کننده باینری خواهیم داشت. در هر دو روش برچسب نهایی داده از طریق روش رأی‌گیری حداکثر تعیین می‌شود. Lin و Hsu [۲۱] در بررسی‌های خود نشان دادند که OAO معمولاً عملکرد بهتری دارد.

۳-۳. سیستم استنتاج عصبی- فازی تطبیقی

نظریه فازی برای اولین بار توسط پروفیسور لطفی‌زاده در سال ۱۹۶۵ معرفی گردید [۲۱] و سپس در بسیاری از فرآیندهای صنعتی و مسائل مختلف مهندسی با موفقیت مورد استفاده قرار گرفت. در سال ۱۹۹۳، Jang [۲۲] با استفاده از توانایی استنتاج سیستم فازی و قابلیت یادگیری و انطباق‌پذیری شبکه عصبی، سیستم استنتاج عصبی- فازی تطبیقی (ANFIS) را ارائه داد. در این سیستم‌ها کلیه پارامترهای مربوط به قوانین فازی را می‌توان با استفاده از خاصیت یادگیری شبکه‌های عصبی تنظیم کرد. به‌طور کلی در طراحی مدل ANFIS ابتدا یک سیستم استنتاج فازی (FIS)^۴ پایه ایجاد شده، و سپس با الگوریتم‌های آموزشی موجود مانند back propagation و یا hybrid، پارامترها به‌گونه‌ای تنظیم می‌شوند که اختلاف خروجی مدل با مقدار واقعی حداقل شود.

روش‌های تقسیم‌بندی شبکه‌ای^۵ و خوشه‌بندی کاهشی^۶ از جمله روش‌های طراحی FIS پایه می‌باشند. تفاوت عمده این دو روش در چگونگی تعیین تابع عضویت^۷ فازی است. در روش تقسیم‌بندی شبکه‌ای، نوع و تعداد تابع عضویت بردار اطلاعات ورودی توسط کاربر تعیین می‌شود. در روش خوشه‌بندی کاهشی، مشخصات تابع عضویت با توجه به اطلاعات ورودی توسط خود مدل تعیین می‌شود، اما در این روش نیز، پارامتری مهم و تأثیرگذار تحت‌عنوان محدودده نفوذ^۸ خواهیم داشت، که باید توسط کاربر تعیین شود. در این تحقیق با توجه به معایب ذکر شده در دو روش قبل و زمانبر بودن آنها از روش مبتنی بر خوشه‌بندی فازی (Fuzzy C-Means) برای طراحی استفاده شده است. در این روش، داده‌ها براساس شباهتشان به چند گروه (خوشه) تقسیم شده و سپس مدل فازی با تعداد قواعد برابر با تعداد خوشه‌ها، برای تمییز دادن هر یک از خوشه‌ها ایجاد می‌گردد. در شکل ۳ ساختار ANFIS با دو ورودی x و y و یک خروجی f نشان داده شده است.

قوانین سیستم فازی در ANFIS از نوع تاکاگی سوگنو مرتبه اول و به صورت زیر در نظر گرفته می‌شوند.

Rule i: If x is A_i and y is B_i , then $f_i = px + qy + r_i$

که در آن A_i و B_i مجموعه‌های فازی هستند و p_i ، q_i و r_i پارامترهایی هستند که در طی فرآیند آموزش تعیین می‌شوند. ساختار ANFIS از پنج لایه تشکیل می‌شود. لایه اول مربوط به محاسبه توابع عضویت می‌باشد و خروجی O_i^1 مقادیر عضویت هر

⁵ Grid Partitioning

⁶ Subtractive Clustering

⁷ Membership Function

⁸ Range of Influence

¹ Multi-Layer Perceptron

² One Against All

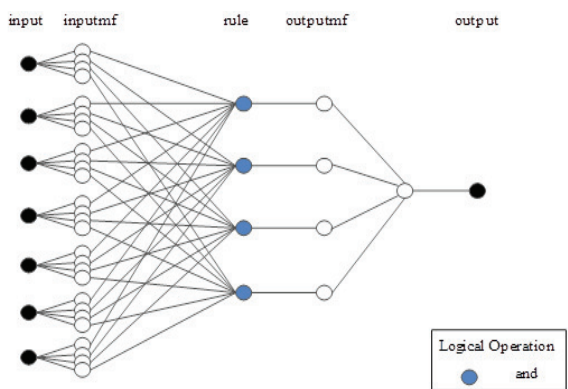
³ Ane Against One

⁴ Fuzzy Inference System

تمامی ورودی‌های به این گره را بر عهده دارد، خروجی نهایی مدل را مطابق رابطه (۱۴) محاسبه می‌کند.

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (14)$$

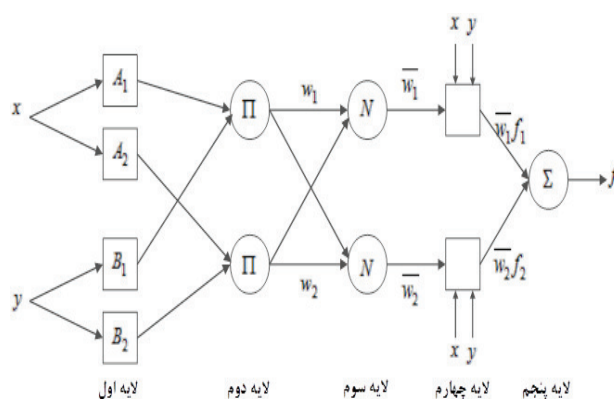
لازم به ذکر است که یکی از مشخصه‌های مهم مدل ANFIS نوع تابع عضویت در نظر گرفته شده برای ورودی‌های مدل می‌باشد. از جمله این توابع می‌توان به توابع عضویت ذوزنقه‌ای، مثلثی و گوسین اشاره کرد. برای انتخاب نوع تابع عضویت، مدل ANFIS برای هر کدام از این توابع به صورت جداگانه آموزش می‌بیند. در پایان میزان خطای مدل‌ها با هم مقایسه می‌شود و تابعی که کمترین میزان خطا را داشته باشد به عنوان تابع عضویت انتخاب خواهد شد. در این تحقیق، توابع عضویت ورودی از نوع توابع عضویت گوسین تعریف شده‌اند. ساختار کلی ANFIS مورد استفاده در روش MOGA-ANFIS با فرض انتخاب ۷ ویژگی PoISAR در شکل ۴ نمایش داده شده است.



شکل ۴. ساختار ANFIS مورد استفاده در این تحقیق با ۷ ویژگی ورودی در این ساختار، ۴ تابع عضویت (به تعداد کلاس‌ها) به هر ورودی اختصاص یافته و ۴ قانون فازی نیز برای توصیف فرآیند و ساخت مدل تعریف شده است. همچنین به ازای هر قاعده، یک تابع عضویت خروجی ثابت و یا خطی در نظر گرفته می‌شود که در اینجا از توابع خطی استفاده شده است.

۳-۴. روش‌های مبنا

در این تحقیق، به منظور ارزیابی روش‌های پیشنهادی از دو روش مبنا استفاده شده است. اولین روش، استفاده از طبقه‌بندی کننده ویشارت بر مبنای ۹ المان ماتریس کواریانس [۲۳] می‌باشد. ماتریس کواریانس پلاریمتریک Z را می‌توان به وسیله توزیع مختلط چند متغیره ویشارت توصیف کرد. اگر $C_m = E(Z|W_m)$ ماتریس کواریانس میانگین برای کلاس W_m باشد، بر اساس طبقه‌بندی کننده



شکل ۳. ساختار ANFIS با دو ورودی و یک خروجی

ورودی نسبت به توابع عضویت مختلف مربوط به آن ورودی است.

$$O_i^1 = \mu_{A_i}(x) \quad i=1,2 \quad (8)$$

$$O_i^1 = \mu_{B_{i-2}}(y) \quad i=3,4 \quad (9)$$

که x و y ، ورودی‌ها به گره i هستند و توابع عضویت فازی معمولاً به صورت رابطه (۱۰) انتخاب می‌شوند.

$$\mu_{A_i} = e^{-\frac{(x-c_i)^2}{2\sigma_i^2}} \quad i=1,2 \quad (10)$$

در این رابطه c_i و σ_i پارامترهای بخش مقدم قوانین فازی و می‌شود نشان‌دهنده میانگین و انحراف تابع گوسین می‌باشند. لایه دوم مربوط به تشکیل قوانین فازی می‌باشد. در این لایه هیچ‌گونه تنظیم یا تطبیقی روی پارامترها صورت نمی‌گیرد، مقادیر ورودی به هر گره در هم ضرب شده و حاصل که وزن قانون‌ها و به عبارتی میزان تأثیر هر قانون در خروجی نهایی می‌باشد، به دست می‌آید.

$$O_i^2 = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \quad (11)$$

لایه سوم لایه نرمالیزاسیون می‌باشد. وزن نسبی قوانین به صورت رابطه (۱۲) در نظر گرفته می‌شود:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (12)$$

خروجی لایه چهارم از ضرب خروجی لایه سوم در یک چند جمله‌ای مرتبه اول تشکیل شده و از رابطه (۱۳) محاسبه می‌شود. در این رابطه، پارامترهای p_i ، q_i و r_i پارامترهای بخش تالی قوانین در مدل فازی تاکاگی سوگنو هستند.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (13)$$

در لایه پنجم، تنها گره موجود در این لایه که وظیفه جمع‌بندی

جدول ۲. تعداد نمونه‌های آموزش و آزمون

آزمون	آموزش	کلاس
۳۱۲	۵۹	آب
۳۱۸	۵۵	ساختمان
۳۱۱	۶۱	پوشش گیاهی
۳۱۹	۶۵	جاده

به‌ذکر است در مورد روش‌های تجزیه ناهمدوس ابتدا برای کاهش اسپیکل از فیلتر Lee Refined [۲۴] با اندازه 5×5 استفاده شد و سپس پارامترها استخراج گردید، اما ویژگی‌های همدوس قبل از انجام هرگونه فیلترینگ از تصویر استخراج شدند. پس از استخراج ویژگی‌های PolSAR، به‌منظور پیاده‌سازی مدل MOGA-SVM، با توجه به عملکرد مطلوب تابع کرنل پایه شعاعی (RBF) در تحقیقات پیشین از آن برای ایجاد طبقه‌بندی‌کننده SVM استفاده شد و بهینه‌سازی پارامترهای آن همزمان با انتخاب ویژگی انجام گرفت. در روش MOGA-ANFIS نیز همان‌طور که قبلاً اشاره شد، برای ایجاد FIS پایه از روش خوشه‌بندی فازی (FCM) استفاده شده و تابع عضویت گوسین به‌کار گرفته شد. از الگوریتم hybrid نیز که ترکیبی از روش گرادینان نزولی و روش حداقل مربعات خطا می‌باشد، برای آموزش مدل استفاده شده است که روش گرادینان نزولی برای تنظیم پارامترهای غیرخطی بخش مقدم و روش حداقل مربعات خطا برای تعیین پارامترهای خطی بخش تالی به‌کار می‌روند.

همچنین در هر دو روش، هر ژن در NSGA-II معادل با یکی از ویژگی‌های استخراج شده از تصویر می‌باشد و دارای مقدار باینری صفر یا یک است که یک به معنی انتخاب شدن ویژگی مربوطه می‌باشد. جمعیت اولیه، شامل ۱۰۰ راه‌حل در نظر گرفته شده و دقت کلی طبقه‌بندی و تعداد ویژگی‌های انتخابی برای ارزیابی راه‌حل‌ها استفاده گردید. عمل تقاطع با نرخ $0/8$ و با روش ماسک انجام گرفت و مقدار جهش ژنی ۵ درصد تعداد کل ژن‌ها انتخاب شد. شرط توقف نیز تعداد تکرار ۵۰ در نظر گرفته شد.

مجموعه راه‌حل‌های نامغلوب ارائه شده پس از فراهم شدن شرط توقف برای MOGA-SVM در شکل ۶ نشان داده شده است. همان‌طور که قبلاً بیان شد، در روش‌های چندهدفه تنها یک راه‌حل بهینه حاصل نمی‌شود و می‌توان با نظر کارشناس و یا بررسی اطلاعات جانبی هر کدام از راه‌حل‌های جبهه اول (F_1) را مطابق با نیاز کاربر به‌عنوان یک راه‌حل بهینه در نظر گرفت. در این تحقیق با توجه به شکل ۶ راه‌حل با کمترین خطا به‌عنوان راه‌حل انتخابی از F_1 در نظر گرفته شد. ویژگی‌های پلاریمتری راه‌حل‌های انتخابی

حداکثر احتمال و توزیع مختلط ویشارت، معیار فاصله ویشارت به‌صورت رابطه (۱۵) در نظر گرفته می‌شود:

$$d_m = \ln|C_m| + Tr(C_m^{-1}Z) \quad (15)$$


$$d_m^{(i)} \leq d_m^{(j)} \quad \forall w_j \neq w_i \quad (16)$$

طبقه‌بندی با SVM در حالتی که انتخاب ویژگی صورت ننگرفته است، دیگر روش مبنای مورد استفاده در این تحقیق می‌باشد.

۴. مجموعه داده و نتایج پیاده‌سازی

به‌منظور ارزیابی عملکرد روش‌های پیشنهادی تصویر پلاریمتری شهر سانفرانسیسکو مربوط به سنجنده رادارست ۲ در باند C مورد استفاده قرار گرفته است. این داده در مد FQ9 با قدرت تفکیک مکانی در جهت رنج $11/1$ متر در برد نزدیک تا $10/5$ متر در برد دور جمع‌آوری شده است. ابعاد تصویر 1400×800 پیکسل است که ترکیب رنگی پائولی آن در شکل ۵ نشان داده شده است. منطقه مورد مطالعه شامل ۴ کلاس اصلی آب، ساختمان، پوشش گیاهی و جاده می‌باشد. تعداد نمونه‌های آموزش و آزمون در هر کلاس که با استفاده از تصویر پائولی و تصویر google earth منطقه انتخاب شده‌اند، در جدول ۲ آمده است.

برای بررسی نتایج الگوریتم، ابتدا استخراج ویژگی‌های پلاریمتری مطابق با جدول ۱ از تصویر منطقه سانفرانسیسکو انجام شد. لازم



شکل ۵. تصویر RGB Pauli منطقه شهری سانفرانسیسکو که در آن $|S_{hh}+S_{vv}|$ با رنگ آبی، $|S_{hv}|$ با رنگ سبز و $|S_{hh}-S_{vv}|$ با رنگ قرمز نشان داده شده است.

¹ Range Resolution

جدول ۳. ویژگی‌های PolSAR راه‌حل انتخابی در MOGA-SVM

ویژگی‌های بهینه			
A_luen	H(1-A)	HA	H_shannon
RVI	SERD	[T] _{12pha}	[Bar] _{13mod}
[Bar] _{13pha}	[Clou] _{13pha}	[Bar] _{22mod}	[Clou] _{33mod}
[Touzi] _{psi}	[Vanzyl] _{odd}	[Krog] _{kh}	[pow] _{max}

جدول ۴. ویژگی‌های PolSAR راه‌حل انتخابی در MOGA-ANFIS

ویژگی‌های بهینه			
A_luen	H_shannon	RVI	SERD
[Bar] _{12mod}	[Free] _{vol}	[Clou] _{13pha}	[Clou] _{22mod}
[T] _{23mod}	[Holm] _{23pha}	[Holm] _{33mod}	[Touzi] _{alpha}
[Touzi] _{psi}	[Vanzyl] _{vol}	[Yama] _{vol}	[S] ₁₂
[S] ₂₂	[Krog] _{kh}	[Krog] _{ks}	[dop] _{min}

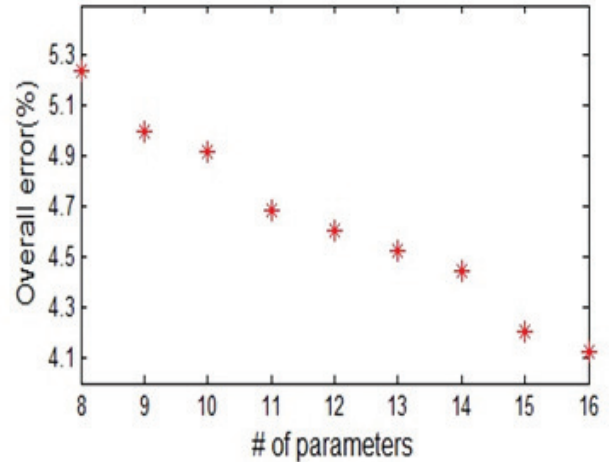
دو روش از دقت بالایی برای مجموعه داده آزمون برخوردارند ولی با این وجود، سیستم ANFIS نتایج بهتری به‌ویژه در کلاس جاده ارائه می‌دهد. لازم به‌ذکر است که استفاده از ANFIS در فرآیند انتخاب ویژگی هزینه محاسباتی نسبتاً بالاتری در مقایسه با به‌کارگیری

جدول ۵. نتایج ماتریس خطا برای بهترین راه‌حل در MOGA-SVM

کلاس	آب	ساختمان	پوشش گیاهی	جاده	دقت تولیدکننده (%)
آب	۳۱۲	۰	۰	۰	۱۰۰
ساختمان	۰	۲۹۶	۶	۱۶	۹۹
پوشش گیاهی	۰	۰	۳۰۹	۲	۹۰/۸۸
جاده	۰	۳	۲۵	۲۹۱	۹۴/۱۷
دقت کاربر (%)	۱۰۰	۹۳/۰۸	۹۹/۳۶	۹۱/۲۲	
ضریب کاپا: ۰/۹۴۵					دقت کلی: ۹۵/۸۷ درصد

جدول ۶. نتایج ماتریس خطا برای بهترین راه‌حل در MOGA-ANFIS

کلاس	آب	ساختمان	پوشش گیاهی	جاده	دقت تولیدکننده (%)
آب	۳۱۲	۰	۰	۰	۱۰۰
ساختمان	۰	۳۰۴	۱۲	۲	۱۰۰
پوشش گیاهی	۰	۰	۳۰۴	۷	۹۴/۱۲
جاده	۰	۰	۷	۳۱۲	۹۷/۲
دقت کاربر (%)	۱۰۰	۹۵/۶	۹۷/۷۵	۹۷/۸۱	
ضریب کاپا: ۰/۹۷					دقت کلی: ۹۷/۷۸ درصد



شکل ۶. مجموعه پار تو بهینه در MOGA-SVM

از دو روش MOGA-SVM و MOGA-ANFIS به‌ترتیب در جدول ۳ و ۴ آمده است.

در جدول ۵ و جدول ۶ ماتریس خطای دو روش حاصل مقایسه پیکسل به پیکسل داده‌های مرجع و نتایج طبقه‌بندی آمده است. ستون‌های این ماتریس معرف داده‌های مرجع و سطرها آن بیانگر نتایج طبقه‌بندی است. با توجه به این جداول می‌توان دریافت که هر

SVM به دنبال داشت.

جدول ۷. مقایسه‌ای از نتایج الگوریتم‌های تک‌هدفه، چندهدفه و روش‌های مینا

الگوریتم	دقت کلی (%)	تعداد ویژگی‌ها
Wishart	۳۲/۷۵	۹
SVM	۴/۹۰	۱۰۵
GAMLP	۳۸/۸۷	۵۶
GASVM	۶۵/۹۳	۳۷
MOGA-SVM	۸۷/۹۵	۱۶
MOGA-ANFIS	۷۸/۹۷	۲۱

دقت طبقه‌بندی و تعداد ویژگی‌های انتخابی، نشان می‌دهد که روش‌های چندهدفه عملکرد بسیار بهتری از جهات مختلف دارند. نقشه طبقه‌بندی نهایی حاصل از بهترین راه‌حل در برخی از روش‌ها و نحوه نمایش رنگی کلاس‌های طبقه‌بندی شده در شکل ۷ نمایش داده شده است.


در ادامه به منظور مقایسه روش‌های بهینه‌سازی چندهدفه و تک‌هدفه دو روش ترکیبی از الگوریتم ژنتیک و ماشین بردار پشتیبان (GASVM) و همچنین شبکه عصبی پرسپترون چندلایه (GAMLP) پیاده‌سازی شد. در این روش‌های تک‌هدفه تنها از دقت کلی طبقه‌بندی برای ارزیابی راه‌حل‌ها استفاده گردید. شبکه MLP طراحی شده شامل سه لایه می‌باشد. تعداد نرون لایه ورودی برابر با تعداد ژن‌هایی که دارای مقدار یک هستند، تعداد نرون لایه میانی برابر با ۵ و لایه خروجی شامل یک نرون ارائه‌دهنده برچسب کلاس در نظر گرفته شده است. در جدول ۷ مقایسه‌ای از بهترین نتایج حاصل از دو روش GASVM و GAMLP، طبقه‌بندی‌کننده SVM با مجموعه ویژگی کامل و طبقه‌بندی‌کننده ویشارت آمده است. نتایج نشان می‌دهد که وارد کردن SVM در فرآیند انتخاب ویژگی علاوه بر کاهش تعداد ویژگی‌های انتخابی، افزایش دقت طبقه‌بندی را نیز به دنبال خواهد داشت. لازم به ذکر است که GASVM هزینه محاسباتی را نسبت به GAMLP به طور قابل توجهی کاهش می‌دهد. همچنین نتایج مقایسه روش‌های چندهدفه و سایر روش‌ها از نظر



(ب)



(الف)



(د)



(ج)

شکل ۷. نتیجه طبقه‌بندی نهایی حاصل از روش‌های (الف) SVM، (ب) GAMLP، (ج) GASVM و (د) MOGA-ANFIS

۵. نتیجه‌گیری

در این تحقیق پتانسیل داده پلاریمتری رادارست ۲ در بهبود طبقه‌بندی پوشش زمین منطقه شهری مورد بررسی قرار گرفت. در همین راستا و به منظور انتخاب حداقل ویژگی‌های بهینه و همزمان افزایش دقت طبقه‌بندی دو روش چندهدفه MOGA-SVM و MOGA-ANFIS به کار گرفته شد. دقت متوسط طبقه بندی با استفاده از روش‌های چندهدفه به بالای ۹۵ درصد رسید. در کل نتایج به دست آمده نشان داد که الگوریتم چندهدفه ویژگی‌های مناسبی را برای طبقه‌بندی انتخاب می‌کند، به نحوی که با تعداد ویژگی‌های کمتر می‌توان به دقت بالاتری در مقایسه با سایر روش‌ها رسید. بنابراین می‌توان ویژگی‌های موجود در فضای ویژگی را به تعدادی بهینه کاهش داد، به طوری که در ضمن کاهش هزینه محاسباتی اطلاعات مفید و مهم پراکنش‌های فضای تصویر را حفظ کرد. علاوه بر این، در این پژوهش سیستم‌های عصبی-فازی با توانایی مدل‌سازی عدم قطعیت‌ها و قابلیت آموزش پذیری از اطلاعات موجود کارایی خوبی در طبقه‌بندی تصویر پلاریمتری از خود نشان دادند. همچنین سیستم طراحی شده با کاهش تعداد قوانین فازی تأثیر زیادی در میزان حافظه و زمان مورد نیاز برای پیاده‌سازی ساختار مورد نظر داشته و از شفافیت و تفسیرپذیری مناسب برخوردار است. از دیگر مزایای مهم الگوریتم پیشنهادی صحت مطلوب طبقه‌بندی نهایی با تعداد نقاط آموزشی کم می‌باشد. بنابراین با استفاده از روش‌های پیشنهادی داده رادارست ۲ می‌تواند اطلاعات بسیار مفیدی برای تمایز بین کلاس‌های مختلف طبیعی و ساخت بشر در اختیار قرار دهد.

۶. مراجع

- [5] Qi, Z., Yeh, A. G., Li, X. and Lin, Z. "A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data," *Remote Sensing of Environment*, vol. 118, pp. 21-39, 2012.
- [6] Maghsoudi, Y., Collins, M. and Leckie, D. "Polarimetric classification of boreal forest using nonparametric feature selection and multiple classifiers," *International Journal of Applied Earth Observation and Geoinformation*, vol. 19, pp. 139-150, 2012.
- [7] Zhu, Z., Ong, Y. S. and Dash, M. "Wrapper-Filter Feature Selection Algorithm Using a Memetic Framework," *IEEE Transactions On Systems, Man and Cybernetics - Part B*, vol. 37, no. 1, pp. 70-76, 2007.
- [8] Cloude, S.R. and Pottier, E. "A review of target decomposition theorems in radar polarimetry," *IEEE Trans. Geosci. Remote Sensing*, vol. 34, no. 2, pp. 498-518, 1996.
- [9] Pottier, E. and Ferro-Famil, L. "Polarimetric Decompositions, Radar Polarimetry," *PolSARPro, Version 3.0, The Polarimetric SAR Data Processing and Educational Tool*, 2005.
- [10] Krogager, E. "New decomposition of the radar target scattering matrix," *Electronics Letters*, vol. 26, pp. 1525-1527, 1990.
- [11] Lee J.S. and Pottier, E. *Polarimetric Radar Imaging from basic to application*. CRC press, 2009.
- [12] Dash, M. and Liu, H. "Consistency-based search in feature selection," *Artificial Intelligence*, vol. 151, pp. 155-176, 2003.
- [13] Lardeux, C., Frison, P.L., Tison, C., Souyris, J.C., Stoll, B., Fruneau, B. and Rudant, J.P. "Support Vector Machine for Multifrequency SAR Polarimetric Data Classification," *IEEE Transaction on Geoscience and Remote Sensing*, vol. 47, no. 12, pp. 4143-4152, dec. 2009.
- [14] Deb, K., Pratap, A., Agarwal, S. and Meyarivan, T. "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Trans. Evol. Comp.*, vol. 6, no. 2, pp. 182-197, 2002.
- [15] Vapnik, V. N. 1995, *The nature of statistical learning theory*. New York: Springer-Verlag.
- [16] Foody, G.M. and Mathur, A. "A relative evaluation of multiclass image classification by support vector machines," *IEEE Transaction on Geoscience and Remote Sensing*, vol. 42, no. 6, pp. 1335-1343, 2004.
- [17] Huang, C., Townshend, J. R. G. and Davis, L. S. "An assessment of support vector machines for land cover classification," *International Journal of Remote Sensing*, vol. 23, pp. 725-749, 2002.
- [18] Melgani, F. and Bruzzone, L. "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Transaction on Geoscience and Remote Sensing*, vol. 42, no. 8, pp. 1778-1790, 2004.
- [1] Ban, Y. and Hu, H. "RADARSAT Fine-Beam SAR Data for Land-Cover Mapping and Change Detection in the Rural-Urban Fringe of the Greater Toronto Area," *Proceedings, Urban Remote Sensing Joint Event*, 2007.
- [2] Haddadi, A., Sahebi, M. R. and A. Mansourian, "Polarimetric SAR feature selection using a genetic algorithm," *Canadian Journal of Remote Sensing*, vol. 37, no. 1, pp. 27-36, 2011.
- [3] Lardeux, C., Frison, P.L., Tison, C., Souyris, J.C., Stoll, B., Fruneau, B. and Rudant, J.P. "Support Vector Machine for Multifrequency SAR Polarimetric Data Classification," *IEEE Transaction on Geoscience and Remote Sensing*, vol. 47, no. 12, pp. 4143-4152, 2009.
- [4] Ince, T., Kiranyaz, S. and Gabbouj, M. "Evolutionary RBF classifier for polarimetric SAR images," *Expert Syst. Appl.*, vol. 39, no. 5, pp. 4710-4717, 2012.

- [23] Lee, J.S. Grunes, M.R. and Pottier, E. "Quantitative comparison of classification capability: fully polarimetric versus dual and singlepolarisation SAR," IEEE Transaction on Geoscience and Remote Sensing, vol. 39, no. 11, pp. 2343-2351, 2001.
- [24] Lee, J.S. Grunes, M.R. and de Grandi, G. "Polarimetric SAR speckle filtering and its implication for classification," IEEE Transaction on Geoscience and Remote Sensing, vol. 37, pp. 2363-2373, 1999.
- [19] Frohlich, H. Chapelle, O. and Scholkopf, B. "Feature selection for support vector machines by means of genetic algorithm," In Proceedings of 15th IEEE International Conference on Tools with Artificial Intelligence, pp. 142-148, 2003.
- [20] Hsu, C.W. and Lin, C. J. "A comparison of methods for multi-class support vector machines," IEEE Transactions on Neural Networks. vol. 13, no. 2, pp. 415-425, 2002.
- [21] Zadeh, L.A. "Fuzzy Sets," Information Control, vol. 8, pp. 338- 535, 1965.
- [22] Jang, J.S.R "ANFIS: Adaptive-Network-Based Fuzzy Inference System," IEEE Transactions On Systems, Man and Cybernetics, vol. 23, no. 3, pp. 665-685, 1993.

Archive of SID

Improving the Urban Area Classification Using Radar Polarimetric Data and multiobjective optimization methods

M. Salehi, Y. Maghsoudi, M. R. Sahebi*

*Faculty of Geodesy and Geomatics Engineering, K.N. Toosi University of Technology

(Received: 06/11/2013, Accepted: 12/13/2013)

Abstract

Land cover classification is one of the most important applications of polarimetric radar images, especially in urban areas. There are numerous features that can be extracted from these images for the use of their high potential, hence feature selection plays an important role in PolSAR image classification. In this study, three main steps are used to improve the classification: 1) feature extraction in the form of three categories, namely original data features, target decomposition features, and SAR discriminators; 2) selection of minimum number of features to achieve the high classification accuracy; and 3) classification using the best subset of features. In the proposed methods, NSGA-II multiobjective optimization algorithm is employed as the search tool and Support Vector Machine (SVM) or Adaptive Neuro Fuzzy Inference System (ANFIS) is used in the evaluation step. The implementation results on the Radarsat-2 San Francisco Bay image showed that the proposed methods outperform the other approaches tested against them.

Keywords: Polarimetric Data, Feature Selection, Classification, Multiobjective Optimization, Support Vector Machine (SVM), Adaptive Neuro Fuzzy, Inference System (ANFIS)

*Corresponding author Email: sahebi@kntu.ac.ir