

انتخاب ویژگی‌های قطبی استخراج شده از تصاویر قطبی رادار دهانه مصنوعی بر مبنای اطلاعات

متقابل ویژگی‌ها به منظور طبقه‌بندی پوششی سطح زمین

محسن درویش نژاد^{۱*}، محمدعلی سبط^۲

۱- دانشجوی دکترا، ۲- دانشیار، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

(دریافت: ۱۴۰۰/۰۸/۲۴، پذیرش: ۱۴۰۱/۰۹/۱۹)

چکیده

در سالیان اخیر، طبقه‌بندی پوششی سطح زمین به‌عنوان یکی از مهم‌ترین کاربردهای تصاویر قطبی استخراج شده از رادار دهانه مصنوعی عنوان شده است. داده‌های قطبی راداری ذاتاً دارای ویژگی‌های مناسبی برای طبقه‌بندی اهداف مختلف سطح زمین می‌باشند؛ لذا به‌منظور استفاده بالا و مناسب از پتانسیل بالای اطلاعاتی از این دادگان می‌توانیم ویژگی‌های متعددی از آنها استخراج نماییم؛ لذا استخراج ویژگی از این دادگان گام مهمی در طبقه‌بندی اهداف سطح زمین می‌باشد. در این مقاله، هدف استخراج و انتخاب ویژگی از تصاویر قطبی رادار دهانه مصنوعی به شکلی است که نرخ طبقه‌بندی اهداف موجود در سطح زمین بهبود پیدا کند. در این مقاله، چهار گام اساسی برای بهبود دقت طبقه‌بندی اتخاذ شده است: ۱- استخراج ویژگی قطبی راداری در قالب سه گروه ویژگی به نام‌های: ویژگی‌های اصلی، ویژگی‌های تجزیه هدف و تفکیک‌کننده‌های رادار دهانه مصنوعی. ۲- طبقه‌بندی اولیه دادگان با استفاده از ویژگی‌های استخراج شده. ۳- تبه‌بندی ویژگی‌ها بر اساس اطلاعات متقابل بین ویژگی‌ها و نقشه طبقه‌بندی اولیه به‌دست‌آمده در مرحله دوم. ۴- به‌دست‌آوردن ویژگی‌های بهینه با استفاده از روش‌های پیشنهادی و طبقه‌بندی نهایی. در روش پیشنهادی از طبقه‌بند ماشین بردار پشتیبان به‌منظور طبقه‌بندی دادگان استفاده خواهد شد و ویژگی‌های بهینه به‌نحوی که نرخ طبقه‌بندی افزایش پیدا کند، انتخاب خواهند شد. نتایج حاصله بر روی تصویر راداری منطقه Flevoland حاکی از افزایش دقت طبقه‌بندی روش پیشنهادی نسبت به سایر روش‌های مورد استفاده در این تحقیق است.

کلیدواژه‌ها: طبقه‌بندی پوششی سطح زمین، رادار دهانه مصنوعی، تصاویر قطبی، انتخاب ویژگی.

۱- مقدمه

امروزه داده‌های راداری دارای پتانسیل بالایی برای استخراج اطلاعات مربوط به علوم مرتبط با زمین بوده‌اند و این لزوم روش‌های تحلیل و استخراج اطلاعات از این داده‌ها را شامل می‌شود [۱]. داده‌های راداری در چهار مد استخراج می‌شوند و اطلاعات بسیار زیادی را در اختیار ما قرار می‌دهند [۲]. طبقه‌بندی و تهیه نقشه‌های پوششی یکی از کاربردهای استفاده از دادگان قطبی راداری می‌باشد [۳-۵]. طبقه‌بندی پوشش مناطق زمینی به دلیل اهمیت این مناطق و لزوم مراقبت از آنها یکی از کاربردهای مهم سنجش‌از‌دور می‌باشد و این در حالی است که در بسیاری از مناطق همواره شاهد وجود مه و یا پوشش ابر و شرایط بارانی هستیم که این مسئله باعث عدم توانایی استفاده از تصاویر نوری در این مناطق می‌شود [۴]. بنابراین در این مناطق استفاده از تصاویر رادار با روزه مصنوعی^۱ [۵] اولویت دارد. در سالیان اخیر، ظهور سامانه‌های تصویربرداری رادار دهانه مصنوعی فضا برد با وضوح مکانی [۶] بالا امکان استخراج اطلاعات جزئی را از

پوشش زمین در مناطق شهری، فراهم آورده است. امروزه، توانایی داده‌های قطبی برداشت شده توسط سنجنده راداری در طبقه‌بندی گونه‌های مختلف در تحقیقات زیادی اثبات شده است [۷]. به‌عنوان مثال بن و همکاران در [۸] نشان داده‌اند که داده‌های رادار است یک پتانسیل خوبی برای تهیه نقشه پوشش سطح زمین دارند؛ اما تنها دارای اطلاعات قطبیت افقی^۲ هستند [۹] لذا، با پرتاب ماهواره رادار است دو در سال ۲۰۰۷ امکان تولید داده‌های قطبی به‌صورت کامل برای این مجموعه ماهواره نیز فراهم گشت [۱۰]. این رادار یکی از پیشرفته‌ترین ماهواره‌های تجاری در باند C است که می‌تواند تصاویر قطبی شامل هر چهار مد به‌صورت کامل دریافت نماید. در این مقاله، هدف ما طبقه‌بندی اهداف موجود در تصاویر قطبی استخراج شده از رادار دهانه مصنوعی می‌باشد. تصاویر استخراج شده توسط این رادارها دارای ویژگی‌های مناسبی برای طبقه‌بندی پوششی سطح زمین می‌باشند [۱۱]. همچنین می‌توان گفت که اگرچه به‌منظور استفاده از دادگان قطبی ویژگی‌های متعددی می‌توان از آنها استخراج نمود، ولی هیچ‌کدام به‌تنهایی برای

* رایانامه نویسنده مسئول: Mohsendarvishnehzadd@gmail.com

^۱ Synthetic Aperture Radar (SAR)^۲ Horizontal

آزمایش‌ها بر روی دادگان قطبی رادار دهانه مصنوعی نشان از برتری روش‌های پیشنهادی نسبت به سایر روش‌های سنتی دارد.

ساختار مقاله را می‌توان به صورت زیر تشریح کرد: در ادامه و در بخش دوم این مقاله ویژگی‌های قطبی به‌طور کلی معرفی می‌شوند. در بخش سوم به معرفی طبقه‌بند ماشین بردار پشتیبان^۲ که به‌عنوان طبقه‌بند در این مقاله استفاده خواهد شد، خواهیم پرداخت. در بخش چهارم دادگان قطبی راداری مورد استفاده در این مقاله را بیان خواهیم کرد. در بخش پنجم به معرفی دو روش پیشنهادی به‌منظور انتخاب دسته ویژگی‌های بهینه خواهیم پرداخت. در بخش ششم نیز نتایج آزمایش‌ها را بیان خواهیم کرد و در نهایت در بخش ششم به جمع‌بندی مقاله خواهیم پرداخت.

۲- روش تحقیق

در سیستم‌های قطبی راداری موجی با یک زاویه مشخص به سمت هدف مورد نظر گسیل می‌شود و این موج توسط هدف به همه جهات پخش می‌شود و یا در اصطلاح پراکنش می‌گردد [۱۷]. سیستم رادار قسمتی از موج پراکنش شده که به سمت آنتن می‌آید را دریافت می‌کند. با کنترل قطبیت موج گسیل شده و موج دریافت شده می‌توان برخی از ویژگی‌های هدف را به دست آورد. سیستم‌های قطبی راداری امواج را به صورت افقی^۳ و عمودی^۴ ارسال کرده و در همان دو قطبیت و در چهار کانال HH-HV-VH-VV با دامنه و فاز مختلف دریافت می‌کنند. می‌توان گفت که اساسی‌ترین منبع اطلاعات سیستم‌های قطبی، ماتریس پراکنش یا پراکنندگی می‌باشد. سیستم‌های قطبی جدید طوری طراحی شده‌اند که با ارسال امواج در قطبیت افقی و عمودی و دریافت هم‌زمان آنها چهار کانال را به وجود می‌آورند که در ماتریسی به نام ماتریس پراکنش یا پراکنندگی به صورت زیر ذخیره می‌شود [۱۸].

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

المان‌های این ماتریس که همگی مختلط می‌باشند با چهار حالت قطبی قابل اندازه‌گیری هستند. اکثر الگوریتم‌های تجزیه هدف از روی این ماتریس (S) نوشته شده‌اند. در حالت کلی ویژگی‌های حاصل از تصاویر قطبی را می‌توان به سه دسته تقسیم کرد [۱۹]

۱- ویژگی‌هایی که به طور مستقیم از داده اصلی به دست می‌آیند.

۲- ویژگی‌های حاصله از الگوریتم‌های تجزیه هدف.

۳- تفکیک‌کننده‌های SAR [۲۰]. در ادامه به معرفی آن‌ها خواهیم پرداخت.

دستیابی به نرخ بالایی از طبقه‌بندی مناسب نمی‌باشند [۱۲]. از طرفی به علت وجود ویژگی‌های اضافی و وابسته استفاده از تمامی آنها عملاً منجر به کاهش نرخ طبقه‌بندی می‌شود که این پدیده به پدیده نفرین ابعاد^۱ شناخته می‌شود [۱۳]. هدف ما در این مقاله استخراج ویژگی‌های مناسب از دادگان قطبی بوده و از میان ویژگی‌های استخراج شده، دسته‌ای از آنها به صورت بهینه به‌گونه‌ای انتخاب شوند که نرخ طبقه‌بندی بیشینه گردد. تاکنون روش‌های مختلفی به‌منظور استخراج و انتخاب ویژگی و طبقه‌بندی تصاویر قطبی رادار دهانه مصنوعی یا PolSAR ارائه شده است [۳]. به‌عنوان مثال صالحی و همکاران در [۱۴] به‌منظور انتخاب ویژگی بهینه و هم‌زمان افزایش دقت طبقه‌بندی از دو روش چندهدفه MOGA-SVM و MOGA ANFIS استفاده کردند که دقت متوسط طبقه‌بندی با استفاده از روش‌های چندهدفه به بالای ۹۵ درصد رسید. همچنین، مقصودی و همکاران در [۱۵] با استفاده از الگوریتم‌های انتخاب ویژگی‌های بهینه از ۵۸ پارامتر اولیه رادار است ۲ در طبقه‌بندی جنگل استفاده کردند. به این صورت که با انتخاب ویژگی باتوجه به جدایی‌پذیری هر کلاس نسبت به کلاس‌های دیگر، فضای ویژگی را به چند زیر فضا تقسیم کردند و با اعمال طبقه‌بندی ماشینی بردار پشتیبان روی هر زیر فضا و ادغام نتایج آنها در پایان به بهبودی در دقت رسیدند. همچنین Samiappan در [۱۶] نیز روشی بر مبنای تلفیق چند طبقه‌بندی کننده ماشینی بردار پشتیبان روی تصاویر اجرا کردند. به این صورت که پس از جدا کردن فضای ویژگی به قسمت‌های نابرابر و بر طبق یک معیار ارزیابی با انتخاب ویژگی به صورت تصادفی در روی هر زیر فضا برای هر طبقه‌بند به دست آورد و نتایج پایانی با رأی‌گیری وزن‌دار ادغام شد که نتایج حاصل از آزمایش‌ها آنها نشان از افزایش نرخ طبقه‌بندی در نتایج داشت.

در این مقاله، برای انتخاب دسته ویژگی بهینه و رسیدن به نرخ طبقه‌بندی بیشینه و پیچیدگی محاسباتی پایین، از روش رتبه‌بندی ویژگی‌ها استفاده خواهیم کرد. بدین صورت که در ابتدا، با استفاده از ویژگی‌های قطبی استخراج شده نقشه طبقه‌بندی اولیه استخراج خواهد شد. با استفاده از نقشه طبقه‌بندی اولیه به دست آمده، برای هر ویژگی بر اساس اطلاعات متقابل آن با نقشه حاصله، رتبه خاصی در نظر گرفته می‌شود. بدین صورت که ویژگی‌هایی که مقدار اطلاعات متقابل حاصله از آنها بیشتر باشد دارای رتبه بالاتری نسبت به ویژگی‌هایی هستند که اطلاعات متقابل حاصله از آنها مقدار پایین‌تری دارد. در نهایت با دو روش پیشنهاد شده و بر معیار رتبه آنها، دسته بهینه‌ای از ویژگی‌ها انتخاب می‌گردد. علاوه بر این، نتایج

^۱ Cure of Dimensional

^۲ Support Vector Machine

^۳ Horizontal (H)

^۴ Vertical (V)

در تجزیه همدوس، ماتریس پراکندگی قطبی به تعدادی ماتریس پراکندگی پایه تجزیه می‌شود. تجزیه ناهمدوس، ماتریس کوواریانس و یا ماتریس همدوسی را به تعدادی توصیفگر درجه دوم تجزیه می‌کند. از روش‌های همدوسی که در این مقاله استفاده شده است می‌توان به: تجزیه‌های کروگاگر^۱ و کامرن^۲ اشاره کرد و همچنین در روش‌های ناهمدوس الگوریتم‌های تجزیه هویین^۳، هولم^۴، ونز^۵، تجزیه‌های $A/\alpha/H$ ، یاماگوچی^۶، فریمن^۷ و توزی^۸ را می‌توان عنوان کرد [۲۳-۲۲]. لازم به ذکر است که تمامی ویژگی‌ها در محیط نرم‌افزار PolSAR-PRO استخراج شدند [۲۴].

۲-۳- ویژگی‌های حاصله از تفکیک‌کننده‌های SAR

این ویژگی‌ها از روی مجموعه عملیات ریاضی به دست می‌آیند. از جمله این ویژگی‌ها می‌توان به توان کل، درجه قطبیت و ضرایب همبستگی بین کانال‌ها نام برد که مطابق با معادلات ۶ تا ۹ محاسبه می‌شوند [۲۵].

$$Span = |S_{hh}|^2 + |S_{hv}|^2 + |S_{vh}|^2 + |S_{vv}|^2 \quad (۶)$$

$$\rho_{hh-vv} = \frac{\langle S_{hh}S_{vv}^* \rangle}{\sqrt{\langle |S_{hh}|^2 \rangle \langle |S_{vv}|^2 \rangle}} \quad (۷)$$

$$\rho_{hh-hv} = \frac{\langle S_{hh}S_{hv}^* \rangle}{\sqrt{\langle |S_{hh}|^2 \rangle \langle |S_{hv}|^2 \rangle}} \quad (۸)$$

$$\rho_{vv-hv} = \frac{\langle S_{vv}S_{hv}^* \rangle}{\sqrt{\langle |S_{vv}|^2 \rangle \langle |S_{hv}|^2 \rangle}} \quad (۹)$$

در روابط فوق S_{nm} بردارهای حاصله از رابطه (۱) است که n می‌تواند v یا h باشد. ρ نیز بردار ویژگی بدست آمده می‌باشد.

در نهایت ۱۰۳ ویژگی استخراج شده از دادگان قطبی رادار دهانه مصنوعی که در این مقاله استفاده شده است. این ویژگی‌ها در قالب جدول (۱) ارائه شده است. همچنین جدول (۲) شماره هر ویژگی متناظر با آن را نشان می‌دهد. برای اطلاعات بیشتر درباره ویژگی‌های قطبی به مرجع [۲۶] مراجعه شود.

۲-۱- ویژگی‌های مستقیم از داده قطبی

برای استخراج اطلاعات مناسب از تصاویر استخراج شده، سامانه‌های PolSAR اغلب ماتریس پراکندگی را اندازه‌گیری می‌کنند. این ماتریس اطلاعات جامعی را در مورد عارضه هدف در اختیار کاربران قرار می‌دهد که با تحلیل آن می‌توان ویژگی‌های مختلفی را استخراج کنیم. ویژگی‌های حاصل از دو ماتریس کوواریانس (C) و همبستگی (T) که بر اساس تحلیل آماری مرتبه دوم ماتریس پراکندگی حاصل می‌شود، در نهایت به‌عنوان ویژگی‌های اصلی استفاده می‌شوند. ماتریس همبستگی T از بردار هدف پراکنده K_T به شرح زیر تعریف می‌شود:

$$K_T = [S_{hh} + S_{vv} \quad S_{hh} - S_{vv} \quad 2S_{hv}]^t \quad (۲)$$

$$[T] = \langle K_T \cdot K_T^t \rangle \quad (۳)$$

و همچنین ماتریس کوواریانس C از بردار کوواریانس K_C بیان شده است. بردار کوواریانس نمایش برداری از ماتریس پراکنش می‌باشد. این بردار به صورت زیر است:

$$K_C = [S_{hh} + S_{vv} \quad \sqrt{2}S_{hv} \quad S_{vv}]^t \quad (۴)$$

$$[C] = \langle K_C \cdot K_C^t \rangle \quad (۵)$$

ضرب این بردار در ترانهاده مزدوج آن شکلی از ویژگی‌های قطبی در حوزه توان است که ویژگی‌های قطبی یک هدف را به صورت رابطه (۴) بیان می‌کند. همچنین در این روابط (...) نشان دهنده میانگین گیری مکانی، و «t» نشان دهنده ترانهاده می‌باشد. در عبارات فوق T و C یک ماتریس 3×3 می‌باشند [۱۹].

۲-۲- استخراج ویژگی‌ها به‌وسیله روش‌های تجزیه هدف

یکی از فواید استفاده از داده‌های قطبی راداری این است که تصویر سطح زمین را می‌توان با احتمال جدایی‌پذیر بودن انواع مختلف ضرایب باز پراکنش از هم تفکیک کرد. برای این کار با جداکردن ماتریس‌های همبستگی و پراکندگی به توابعی پایه می‌توان به بعضی از هدف‌های از پیش تعیین شده رسید که به این کار روش تجزیه می‌گویند. این روش‌ها باتوجه به نوع ماتریسی که در آن استفاده می‌شود به دودسته تقسیم می‌کنند که شامل دودسته تجزیه همدوس و تجزیه ناهمدوس می‌شوند. روش‌های تجزیه همدوس از ماتریس پراکندگی و روش‌های تجزیه ناهمدوس از ماتریس کوواریانس استفاده می‌کنند. همچنین، تجزیه‌های همدوس برای عوارض ساخت دست بشر مناسب بوده و روش‌های ناهمدوس عوارض طبیعی را بهتر توصیف می‌کنند.

¹ Karougager

² Kamren

³ Huineenin

⁴ Hulm

⁵ Venze

⁶ Yamgouchi

⁷ FreeMan

⁸ Tozi

جدول (۱). ویژگی‌های استخراج شده از تصاویر قطبی رادار دهانه مصنوعی

تعداد ویژگی	نماد در جداول	شرح	تعداد ویژگی
ویژگی‌های اصلی	مولفه‌های ماتریس پراکنش	S	۳
	مولفه‌های ماتریس کواریانس	C	۹
	مولفه‌های ماتریس همبستگی	T	۹
ویژگی‌های استخراج شونده با تجزیه‌کننده‌ها	تجزیه کروگر	Korg	۹
	تجزیه هونین	H	۹
	تجزیه بارنس	B	۹
	تجزیه کلد	C_one	۹
	تجزیه هولم	Hol	۹
	تجزیه ونزیل	V	۳
	تجزیه کلد-پیتر	HA	۱۹
	تجزیه فری من	Fd	۳
	تجزیه توزی	Toz	۴
تجزیه یامگوچی	Y	۴	
تصمیم‌گیرنده‌ها	ضرایب همبستگی	CC	۲
	Span	S_two	۱

جدول (۲). شماره متناظر با نام هر ویژگی استخراج شده. Name نشان‌دهنده نام ویژگی و Num نشان‌دهنده شماره ویژگی است.

Name _F	S _{HH}	S _{HV}	S _{VV}	C11	C12	C13	C21	C22	C23	C31	C32	C33
Num _F	1	2	3	4	5	6	7	8	9	10	11	12
Name _F	T11	T12	T13	T21	T22	T23	T31	T32	T33	Krog ₁	Krog ₂	Krog ₃
Num _F	13	14	15	16	17	18	19	20	21	22	23	24
Name _F	Krog4	Krog5	Krog6	Krog7	Krog8	Krog9	H1	H2	H3	H4	H5	H6
Num _F	25	26	27	28	29	30	31	32	33	34	35	36
Name _F	H7	H8	H9	B1	B2	B3	B4	B5	B6	B7	B8	B9
Num _F	37	38	39	40	41	42	43	44	45	46	47	48
Name _F	C_one ₁	C_one ₂	C_one ₃	C_one ₄	C_one ₅	C_one ₆	C_one ₇	C_one ₈	C_one ₉	Hol1	Hol2	Hol3
Num _F	49	50	51	52	53	54	55	56	57	58	59	60
Name _F	Hol4	Hol5	Hol6	Hol7	Hol8	Hol9	V1	V2	V3	HA1	HA2	HA3
Num _F	61	62	63	64	65	66	67	68	69	70	71	72
Name _F	HA4	HA5	HA6	HA7	HA8	HA9	HA10	HA11	HA12	HA1 ₃	HA1 ₄	HA1 ₅
Num _F	73	74	75	76	77	78	79	80	81	82	83	84
Name _F	HA16	HA17	HA18	HA19	Fd1	Fd2	Fd3	Y1	Y2	Y3	Y4	Toz1
Num _F	85	86	89	89	90	91	92	93	94	95	96	97
Name _F	Toz2	Toz3	Toz4	CC1	CC2	Span						
Num _F	98	99	100	101	102	103						

بردارها اهمیت دارند. در واقع در طبقه‌بند ماشین بردار پشتیبان فاصله بین بردارهای پشتیبان را در جهت عمود بر مرز خطی حداکثر می‌کند [۲۹]. در این روش با حل معادله بهینه‌سازی ذیل مرز خطی و جداساز بین کلاس‌ها حاصل می‌شود.

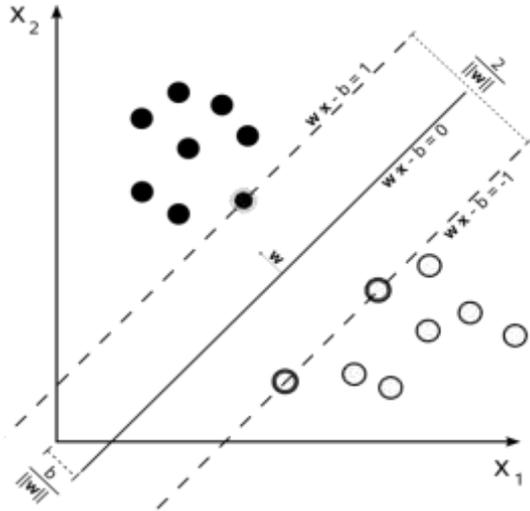
$$\operatorname{argmax}(\min \frac{|b + x_i \cdot w|}{\sqrt{\sum_{i=1}^d w_i^2}}) \quad (10)$$

Subject to: $\forall x_i \in D : y_i(b + x_i \cdot w) \geq 0$

۳- ماشین بردار پشتیبان

طبقه‌بند ماشین بردار پشتیبان [۲۷] یک طبقه‌بند خطی می‌باشد که هدف آن این است که مرز خطی بین کلاس‌ها را به گونه‌ای تعیین کند که فاصله بین نزدیک‌ترین بردارهای پشتیبان در جهت عمود بر مرز بیشینه گردد؛ لذا به این طبقه‌بند، طبقه‌بند حداکثر حاشیه نیز گفته می‌شود. در این طبقه‌بند به فاصله بین نزدیک‌ترین نمونه‌های آموزشی بردار پشتیبان می‌گویند که این بردارها در طی فرایند طبقه بندی طراحی و آموزش داده می‌شوند و در ادامه فرایند فقط این

بین هر کدام از ویژگی‌های استخراج شده از داده قطبی (که در بخش دوم توضیح داده شد) و نقشه طبقه‌بندی اولیه، برای هر ویژگی براساس بزرگی مقدار اطلاعات متقابل آن رتبه خاصی در نظر خواهیم گرفت. هر کدام از ویژگی‌ها که مقدار اطلاعات متقابل آن بیشتر باشد دارای رتبه بالاتری است و برعکس.



شکل (۱). ابر صفحه‌ای با حداکثر حاشیه برای یک ماشین بردار پشتیبان.

۵- مجموعه داده مورد استفاده

داده قطبی Flevoland: به منظور ارزیابی روش پیشنهادی تصویر قطبی منطقه Flevoland مورد استفاده قرار گرفته است. این داده در آگوست ۱۹۸۹ در باند فرکانسی L توسط سامانه NASA/JPL AIRSAR در محیط آزمایشی منطقه Flevoland و به صورت قطبیت کامل تصویربرداری شده است. در این داده ۱۱ کلاس مختلف از پوشش‌های سطح زمین وجود دارد. اندازه این داده ۱۰۲۴×۷۵۰ می‌باشد [۳۴]. نقشه مرجع این داده به صورت شکل (۲) است. جدول (۳) تعداد کل نمونه‌ها، نمونه‌های آموزشی و آزمایشی به تفکیک کلاس‌های این داده را نشان می‌دهد.

که در معادله فوق $b + x.w$ معادله مرز خطی بین کلاس‌ها است [۳۰]. از جمله مزایای این طبقه‌بند به آموزش ساده آن می‌توان اشاره کرد. همچنین برخلاف شبکه‌های عصبی [۳۱] همگرایی ساده‌تری دارد. علاوه بر این، طبقه‌بند ماشین بردار پشتیبان برای داده‌های با ابعاد بالا جواب قابل قبولی از خود ارائه می‌دهد و همچنین مصالحه بین پیچیدگی دسته‌بندی‌کننده و میزان خطا به طور واضح در این طبقه‌بند کنترل می‌شود. در این مقاله از کتاب-خانه طبقه‌بند ماشین بردار پشتیبان Lib-SVM که در [۳۰] پیاده سازی شده است به عنوان طبقه‌بند برای طبقه‌بندی دادگان استفاده خواهیم کرد. شکل ۱، ابر صفحه‌ای با حداکثر حاشیه برای یک ماشین بردار پشتیبان که با نمونه داده‌هایی از دو دسته یادگرفته شده است را نشان می‌دهد. در این شکل، داده‌هایی که بر روی ابر صفحه قرار دارند بردارهای پشتیبان نام دارند.

۴- اطلاعات متقابل

در نظریه احتمالات و اطلاعات، اطلاعات متقابل [۳۱] معیاری برای نشان دادن میزان وابستگی متقابل دو متغیر می‌باشد. به بیان دیگر در حقیقت این معیار «میزان اطلاعات» به دست آمده در مورد یک متغیر تصادفی از طریق متغیر تصادفی دیگر را نشان می‌دهد. مفهوم اطلاعات متقابل ذاتاً مرتبط با آنتروپی یک متغیر تصادفی که میزان اطلاعات موجود در یک متغیر تصادفی را نشان می‌دهد، می‌باشد. اطلاعات متقابل میزان شباهت بین توزیع مشترک $P(x, y)$ و همچنین ضرب احتمال‌های حاشیه‌ای یعنی $P(x) * P(y)$ را مشخص می‌سازد. اطلاعات متقابل بین دو متغیر تصادفی x و y را می‌توان به صورت زیر بیان کرد [۳۲]:

$$I(x, y) = \sum_y \sum_x P(x, y) \log \left(\frac{P(x, y)}{P(x) \cdot P(y)} \right) \quad (11)$$

در معادله فوق توزیع مشترک $P(x, y)$ همچنین، $P(x)$ و $P(y)$ احتمال‌های حاشیه‌ای برای متغیرهای x و y است [۳۳]. در این مقاله از مفهوم اطلاعات متقابل به منظور رتبه‌بندی ویژگی‌ها استفاده خواهیم کرد. بدین صورت که با محاسبه اطلاعات متقابل



شکل (۲). تصویر رنگی و نقشه مرجع برای مجموعه داده منطقه Flevoland

جدول (۳). تعداد کل نمونه‌ها، نمونه‌های آموزشی و آزمایشی به تفکیک کلاس برای داده Flevoland

نام کلاس	تعداد کل نمونه‌ها	تعداد نمونه‌های آزمایشی	تعداد نمونه‌های آموزشی
چغندر	۱۱۷۷۲	۱۱۱۸۳	۵۸۹
لوسرن	۹۲۶۲	۸۷۹۸	۴۶۳
خاک	۱۶۳۸۳	۱۵۵۶۳	۸۱۹
کلزا	۲۶۰۸۶	۲۴۷۸۱	۱۳۰۴
لوبیای بخار	۱۴۲۷۴	۱۳۵۶۰	۷۱۳
سیب‌زمینی	۴۳۰۸۵	۴۰۹۳۰	۲۱۵۴
آب	۲۹۶۶۱	۲۸۱۷۷	۱۴۸۳
چمن	۹۳۲۶	۸۸۵۹	۴۶۶
نخودفرنگی	۱۳۶۸۲	۱۲۹۹۷	۶۸۴
گندم	۶۰۴۵۰	۵۷۴۲۷	۳۰۲۲
جنگل	۲۵۴۱۴	۲۴۱۴۳	۱۲۷۰

ویژگی‌های استخراج شده می‌باشد که در راستای رسیدن به این هدف و در ابتدا با استفاده از مجموعه کامل ویژگی‌های استخراج شده در مرحله قبل و طبقه‌بند ماشین بردار پشتیبان، یک نقشه طبقه‌بندی اولیه حاصل خواهد شد. در ادامه و با استفاده از نقشه طبقه‌بندی اولیه حاصله، اطلاعات متقابل بین هر ویژگی استخراج شده و نقشه طبقه‌بندی اولیه که یک بردار $k \times 1$ خواهد بود، حاصل شده که k برابر است با تعداد ویژگی‌های استخراج شده از تصاویر قطبی رادار دهانه مصنوعی. در گام بعد، به ازای اطلاعات متقابل حاصله، به هر ویژگی رتبه خاصی تعلق می‌گیرد. بدین صورت که هرچه اطلاعات متقابل بین هر ویژگی و نقشه طبقه‌بندی اولیه بیشتر باشد رتبه ویژگی بالاتر می‌باشد و برعکس. در نهایت با استفاده از دو روشی که در ادامه بیان می‌شود مجموعه ویژگی بهینه‌تری انتخاب خواهد شد که دقت طبقه‌بندی تصاویر قطبی رادار دهانه مصنوعی بهینه‌ترین حالت خود را داشته باشد.

۶-۱- روش پیشنهادی اول

در روش پیشنهادی اول، ابتدا ویژگی با بالاترین رتبه (X_1) وارد مجموعه دادگان خواهد شد که در اینجا X نشان‌دهنده هر ویژگی و اندیس آن نشان‌دهنده رتبه می‌باشد. در ادامه ویژگی‌ها به ترتیب رتبه از X_2 تا X_m (که m نشان دهنده تعداد کل ویژگی‌هاست) به شرطی وارد مجموعه می‌شوند که نرخ طبقه‌بندی افزایش پیدا کند، در غیر این صورت ویژگی وارد مجموعه دادگان نخواهد شد. در صورتی که با ورود ویژگی جدید، نرخ طبقه‌بندی افزایشی نداشته

۶- روش پیشنهادی

هدف در این مقاله، همان‌طور که گفته شد انتخاب ویژگی‌های بهینه از تصاویر قطبی رادار دهانه مصنوعی به‌منظور رسیدن به دقت طبقه‌بندی مناسب می‌باشد. به‌طور کلی در صورتی که از همه ویژگی‌های استخراج شده (مشابه بخش ۲) برای طبقه‌بندی تصاویر قطبی رادار دهانه مصنوعی استفاده نماییم، نمی‌توانیم به بهینه‌ترین مقدار دقت طبقه‌بندی دست یابیم. این موضوع به دلیل پدیده نفرین ابعاد^۱ که در [۳۶] بیان شده است، اثبات شده است. به همین جهت، در این مقاله به دنبال روشی برای انتخاب دسته ویژگی‌های بهینه از میان مجموعه ویژگی‌های استخراج شده خواهیم بود و در این راستا دو روش پیشنهادی بیان کرده که بر معیار رتبه‌بندی ویژگی‌ها سعی در انتخاب بهینه‌ترین آنها برای دستیابی به دقت طبقه‌بندی بهینه خواهیم بود. در هر دو روش پیشنهادی و با توجه به شکل (۳)، در ابتدا پیش‌پردازش داده قطبی شامل فیلتر کردن و حذف نویز ذره‌ای [۳۶] از آن بر روی مجموعه دادگان صورت می‌گیرد. در مرحله بعد ویژگی‌های قطبی [۲۶] به سه روش گفته شده در بخش ۲ از تصاویر قطبی راداری استخراج خواهند شد. همان‌طور که گفته شد، در صورتی که از مجموعه کامل ویژگی‌های فوق به‌منظور طبقه‌بندی تصاویر قطبی استفاده نماییم نمی‌توانیم به دقت بهینه‌ای دست یابیم [۳۷] لذا در گام بعد هدف انتخاب دسته ویژگی بهینه از میان

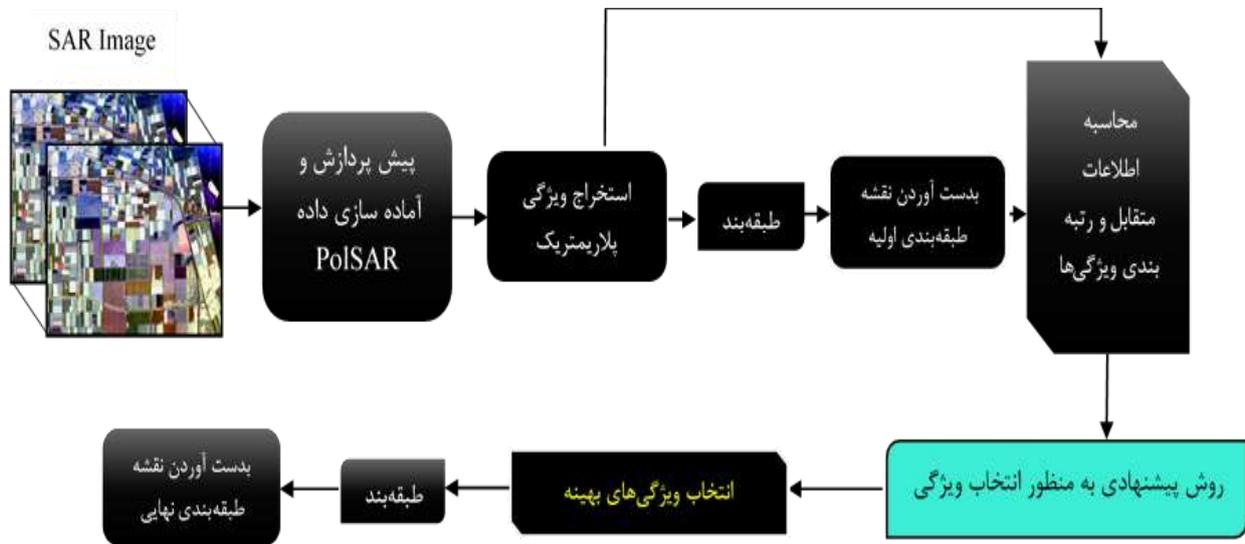
^۱ Curses of dimensionality

مجموعه کنار می‌رود و این روال را تا همگرایی کامل مسئله ادامه خواهد یافت. در زیر مراحل روش پیشنهادی دوم را به صورت جزئی‌تر شرح خواهیم داد.

در نهایت مجموعه ویژگی انتخاب شده در روش اول و دوم، به‌عنوان ورودی طبقه‌بند به‌صورت مجزا در نظر گرفته شده و نرخ طبقه‌بندی به دست می‌آید. در شکل (۳) مراحل روش پیشنهادی قابل مشاهده است. شکل‌های (۴) و (۵) فلوجارت پیشنهادی روش اول و دوم برای انتخاب ویژگی بهینه را نشان می‌دهند. ذکر این نکته ضروری است که علامت - در فلوجارت نشان‌دهنده حذف ویژگی و علامت + نیز نشان‌دهنده اضافه کردن ویژگی می‌باشد. همچنین FS به معنای دسته ویژگی و R نیز به معنای نرخ طبقه‌بندی است.

باشد (درابتدا) ویژگی جدید حذف نمی‌شود و به مرحله قبل بازگشته و ویژگی اضافه شده در مراحل قبل را به ترتیب حذف خواهیم کرد، در صورتی که با حذف ویژگی اضافه شده در مراحل قبل، نرخ طبقه‌بندی با ورود ویژگی جدید افزایش یابد آنگاه ویژگی مذکور حذف خواهد شد و در غیر این صورت ویژگی جدیدی اضافه نمی‌شود. جدول (۴) مراحل روش پیشنهادی اول را به صورت جزئی‌تر نشان می‌دهد.

افزایش نرخ، ویژگی (X_{m-1}) از مجموعه حذف می‌شود. در صورت اینکه با حذف این ویژگی نرخ افزایشی نداشته باشد، ویژگی حذف شده در مرحله قبل (X_m) به مجموعه اضافه می‌شود و سپس نرخ محاسبه می‌گردد، در صورت افزایش نرخ، ویژگی حذف شده مرحله قبل به مجموعه دادگان اضافه می‌شود و ویژگی (X_{m-1}) از



شکل (۳). مراحل روش پیشنهادی

شماره گام	تشریح گام
گام اول	از پایین‌ترین رتبه ویژگی مرحله قبل (ابتدا X_2) شروع به حذف کردن خواهیم کرد و مجموعه جدید $[X_1, X_3]$ حاصل می‌شود و به ازای مجموعه جدید نرخ طبقه‌بندی حساب می‌شود ($Rate_{31}$). در صورتی که $Rate_{31} > Rate_2$ و $Rate_{31} > Rate_1$ باشد، مجموعه جدید $[X_1, X_3]$ انتخاب شده و X_2 از مجموعه حذف می‌شود. مادامی که با حذف ویژگی مراحل قبل، نرخ طبقه‌بندی جدید نسبت به نرخ مراحل قبل افزایش پیدا کند، حذف را ادامه خواهیم داد.
گام چهارم	تکرار گام سوم تا همگرایی کامل مسئله.

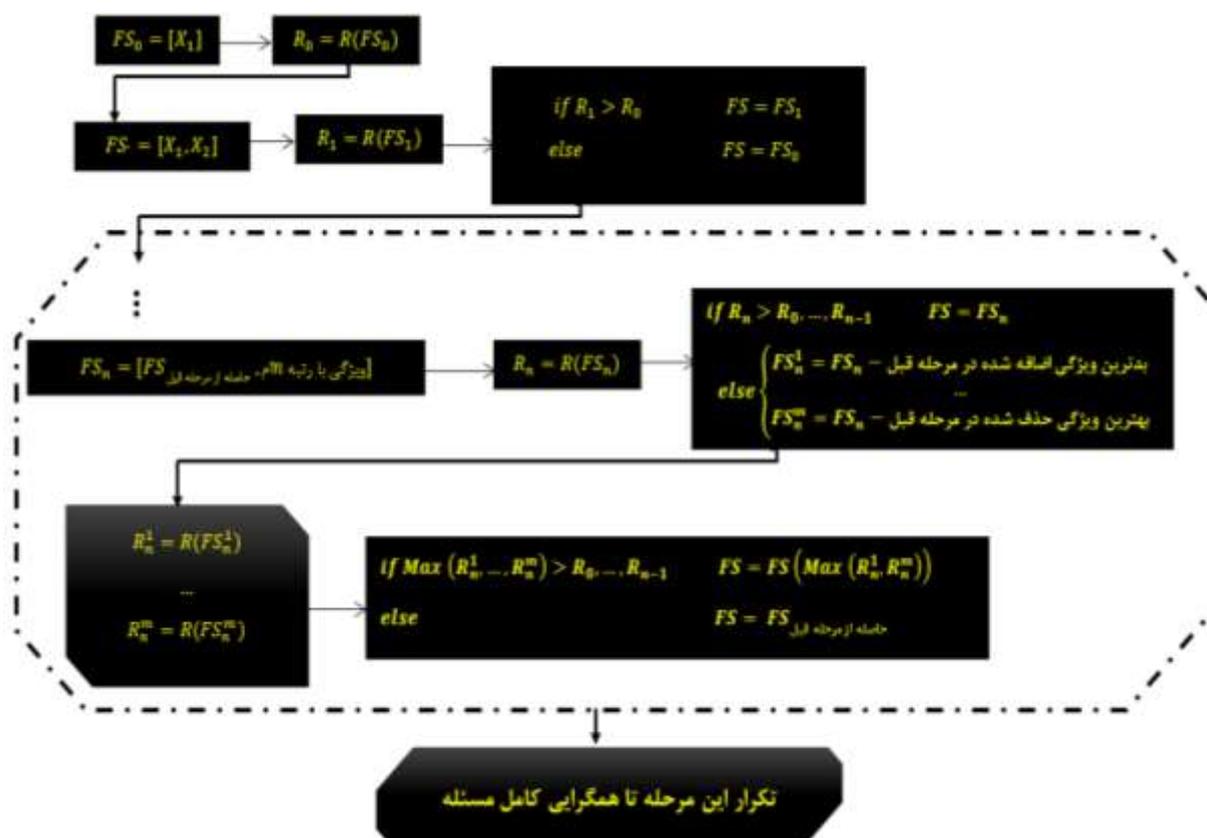
جدول (۵). روش پیشنهادی دوم

شماره گام	تشریح گام
گام اول	به‌ازای تمام مجموعه ویژگی‌ها $[X_1, \dots, X_m]$ نرخ طبقه‌بندی محاسبه می‌گردد ($Rate_1$).

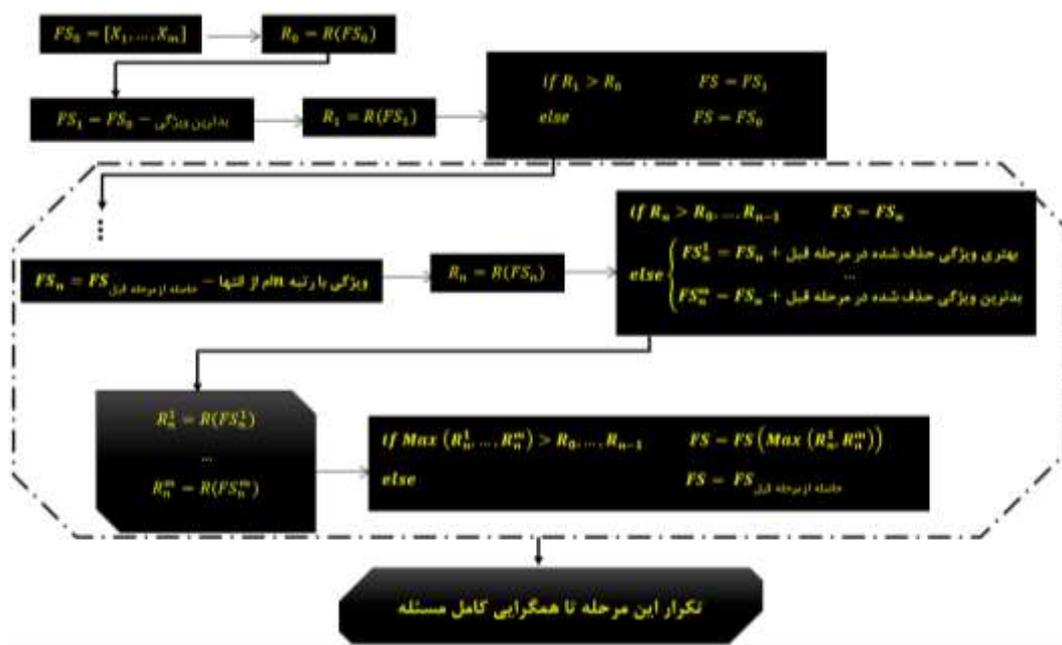
جدول (۴). روش پیشنهادی اول

شماره گام	تشریح گام
گام اول	ویژگی با رتبه اول: X_1 ، وارد طبقه‌بند شده و دقت طبقه‌بندی محاسبه می‌شود ($Rate_1$).
گام دوم	ویژگی با رتبه دوم: X_2 ، به ویژگی مرحله قبل اضافه می‌شود، و نرخ طبقه‌بندی برای مجموعه ویژگی $[X_1, X_2]$ محاسبه می‌شود ($Rate_2$). در صورتی که نرخ طبقه‌بندی افزایش پیدا کند، یعنی $Rate_2 > Rate_1$ باشد، ویژگی اضافه شده (X_2) در مجموعه ویژگی‌ها باقی می‌ماند. در غیر این صورت از مجموعه حذف می‌شود.
گام سوم	ویژگی با رتبه سوم: X_3 ، به مجموعه اضافه شده و دقت طبقه‌بندی به ازای مجموعه $[X_1, X_2, X_3]$ (با فرض ورود X_2 در مرحله قبل) حاصل می‌شود ($Rate_3$). در صورتی که نرخ طبقه‌بندی افزایش پیدا کند، یعنی $Rate_3 > Rate_2$ و $Rate_3 > Rate_1$ باشد، ویژگی اضافه شده (X_3) در مجموعه ویژگی‌ها باقی می‌ماند و در صورتی که نرخ طبقه‌بندی نسبت به گام دوم افزایش پیدا نکرده باشد یعنی $Rate_3 < Rate_2$ به ترتیب و

افزایش نرخ طبقه‌بندی مجموعه مذکور انتخاب می‌گردد و در غیر این صورت مجموعه انتخابی در گام قبل در این مرحله نیز انتخاب می‌گردد.		ویژگی با بدترین رتبه (X_m) از مجموعه ویژگی‌ها کنار رفته و به ازای مجموعه ویژگی $[X_1, \dots, X_{m-1}]$ نرخ طبقه‌بندی حساب می‌شود ($Rate 2$). در صورتی که $Rate 2 > Rate 1$ باشد، ویژگی (X_m) از مجموعه حذف می‌شود و مجموعه ویژگی $[X_1, \dots, X_{m-1}]$ در این گام انتخاب می‌شود. در غیر این صورت این ویژگی در مجموعه باقی می‌ماند و مجموعه ویژگی $[X_1, \dots, X_m]$ در این گام انتخاب می‌شود. به ازای هر کدام از مجموعه‌های باقی مانده نرخ طبقه‌بندی را محاسبه می‌کنیم ($Rate 2_Final$)	گام دوم
ویژگی با جایگاه سوم از نظر بدترین رتبه (X_{m-2}) از مجموعه ویژگی‌ها حذف شده و به ازای مجموعه جدید $[X_1, \dots, X_{m-3}, X_{m-1}, X_m]$ یا $[X_1, \dots, X_{m-3}, X_{m-1}]$ یا $[X_1, \dots, X_{m-3}, X_m]$ (وابسته به انتخاب مرحله قبل) نرخ طبقه‌بندی محاسبه می‌شود ($Rate 4$). در صورتی که $Rate 4 > Rate 3_Final$ باشد، ویژگی (X_{m-2}) از مجموعه کنار می‌رود و مجموعه جدید $[X_1, \dots, X_{m-3}, X_{m-1}, X_m]$ یا $[X_1, \dots, X_{m-3}, X_{m-1}]$ یا $[X_1, \dots, X_{m-3}, X_m]$ (وابسته به انتخاب مرحله قبل) در این گام انتخاب می‌گردد. در غیر این صورت بهترین ویژگی‌های حذف شده در مرحله قبل به ترتیب، به مجموعه فوق اضافه می‌شود و نرخ طبقه‌بندی محاسبه می‌شود. در صورت افزایش نرخ طبقه‌بندی مجموعه مذکور انتخاب می‌گردد و در غیر این صورت مجموعه انتخابی در گام قبل در این مرحله نیز انتخاب می‌گردد.	گام چهارم	ویژگی با جایگاه دوم از نظر بدترین رتبه (X_{m-1}) از مجموعه ویژگی‌ها حذف شده و به ازای مجموعه جدید $[X_1, \dots, X_{m-2}, X_m]$ یا $[X_1, \dots, X_{m-2}, X_m]$ در صورت عدم حذف در مرحله قبل) نرخ طبقه‌بندی محاسبه می‌شود ($Rate 3$). در صورتی که $Rate 3 > Rate 2_Final$ باشد، ویژگی (X_{m-1}) از مجموعه کنار می‌رود و مجموعه $[X_1, \dots, X_{m-2}, X_m]$ (وابسته به مرحله انتخاب قبل) انتخاب می‌شود. در غیر این صورت بهترین ویژگی‌های حذف شده در مرحله قبل به ترتیب، به مجموعه فوق اضافه می‌شود و نرخ طبقه‌بندی محاسبه می‌شود. در صورت	گام سوم
تکرار گام چهارم تا همگرایی کامل مسئله.	گام پنجم		



شکل (۴). فلوجارت پیشنهادی روش اول برای انتخاب ویژگی بهینه



شکل (۵). فلوچارت پیشنهادی روش دوم برای انتخاب ویژگی بهینه

عبارت‌اند از: استخراج ویژگی با استفاده از ماتریس پراکندگی (S)، استخراج ویژگی با استفاده از ماتریس کواریانس (C)، استخراج ویژگی با استفاده از ماتریس همبستگی (T)، انباشته کردن ویژگی‌های ماتریس پراکندگی و همبستگی و کواریانس (Stack Raw)، استخراج ویژگی به روش تجزیه کروگاکر، استخراج ویژگی به روش تجزیه هونین، استخراج ویژگی به روش تجزیه بارس، استخراج ویژگی به روش تجزیه کلد، استخراج ویژگی به روش تجزیه هولم، استخراج ویژگی به روش تجزیه ونزیل، استخراج ویژگی به روش تجزیه ونزیل، استخراج ویژگی به روش تجزیه کلد-پیتر، استخراج ویژگی به روش تجزیه فری من، استخراج ویژگی به روش تجزیه یامگوچی، استخراج ویژگی به روش تجزیه توزی، انباشته شده ویژگی‌های تجزیه هدف (Stack TD)، استخراج ویژگی به روش ضرایب همبستگی (CC)، استخراج ویژگی به روش Span و انباشته کردن همه ویژگی‌های استخراج شده (Stack). همچنین قابل ذکر است که روش‌های فوق با استفاده از دقت سراسری^۲، دقت میانگین^۳ و ضریب کاپا^۴ با یکدیگر مقایسه شده‌اند [۴۱]. جدول (۵) نتایج آزمایش‌ها را نشان می‌دهد. همان‌طور که در جدول (۵) مشخص است بهترین دقت برای روش پیشنهادی اول با دقت سراسری ۹۸,۶۴، دقت میانگین ۹۸,۵۱ و ضریب کاپای ۰,۹۸۳ می‌باشد. همچنین در این روش ۶۱ ویژگی از مجموعه ویژگی‌های استخراج

۷- نتایج آزمایش‌ها

به‌منظور ارزیابی و اثبات کارایی روش‌های مطرح شده در قسمت ششم، روش پیشنهادی خود را با روش‌های سنتی طبقه‌بندی تصاویر قطبی رادار دهانه مصنوعی مقایسه خواهیم کرد. لازم به ذکر است که در تمامی آزمایش‌ها از طبقه‌بند ماشین بردار پشتیبان با کتابخانه Lib SVM استفاده شده است [۳۰]. همچنین، به‌منظور استخراج ویژگی‌های قطبی به روش‌های ناهمدوس، در ابتدا برای کاهش نویز ذره‌ای، از فیلتر Lee Refined با اندازه ۵ استفاده کرده‌ایم [۳۸] اما ویژگی‌های همدوس قبل از هرگونه فیلترکردن استخراج شده‌اند. پس از استخراج ویژگی‌های PolSAR به‌منظور پیاده‌سازی روش پیشنهادی، از هسته پایه شعاعی^۱ [۳۹] برای پیاده‌سازی طبقه‌بند ماشین بردار پشتیبان استفاده شده است. همچنین تمامی آزمایش‌ها در محیط نرم‌افزاری متلب [۴۰] انجام شده است. در طبقه‌بندهای شبیه‌سازی شده به‌منظور اعتباربخشی به نتایج، در هر بار اجرای طبقه‌بندی، ۵ درصد نمونه‌ها به‌عنوان نمونه آموزشی و ۹۵ درصد نمونه‌ها به‌عنوان نمونه آزمایشی استفاده شد و تمامی نتایج پس از ۱۰ بار اجرا و میانگین‌گیری بر روی نتایج در جدول آورده شده‌اند. علاوه بر این و همان‌طور که گفته شد روش‌های پیشنهادی خود را با روش‌های سنتی استخراج ویژگی‌های قطبی از تصاویر رادار دهانه مصنوعی مقایسه خواهیم کرد. این روش‌ها

² Overall Accuracy (OA)

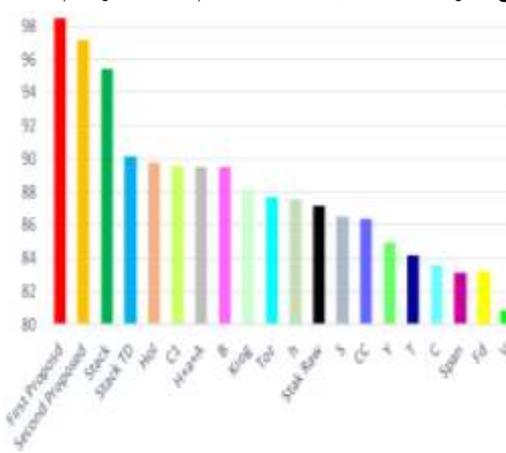
³ Average Accuracy (AA)

⁴ Kappa Coefficient (k)

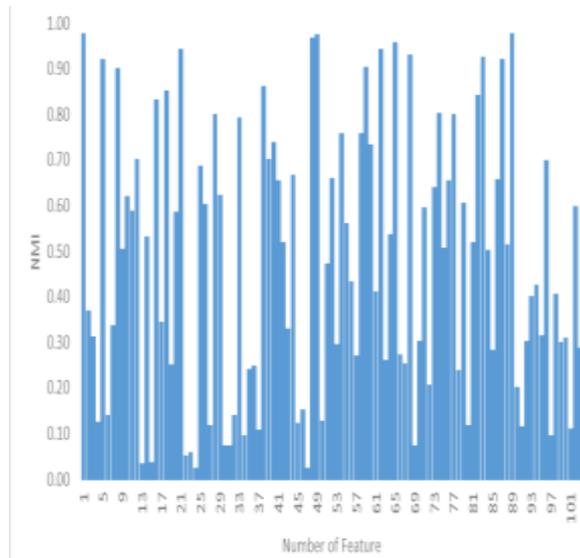
¹ Radial Basis Function

بنابراین، شکل (۶) نشان می‌دهد استفاده از مجموع ویژگی‌ها به‌دقت بالاتری منجر می‌شود اما دقت به‌دست‌آمده، بهینه‌ترین دقت ممکن نمی‌باشد و با انتخاب ویژگی‌های بهینه توسط روش‌های پیشنهادی اول و دوم به‌دقت بالاتری دست پیدا کرده‌ایم. این افزایش دقت را می‌توان این‌گونه بیان کرد که افزایش تعداد ویژگی منجر به پدیده نفرین ابعاد شده و دقت طبقه‌بندی را کاهش داده است و لذا با ارائه روش‌های پیشنهادی مبتنی بر رتبه‌بندی ویژگی‌ها توانسته‌ایم به مجموعه‌ای بهینه از ویژگی‌ها دست پیدا کنیم که بیشترین نرخ طبقه‌بندی را شامل می‌باشد. همچنین شکل (۷) نیز نشان‌دهنده دقت میانگین برای روش‌های پیشنهادی و سایر روش‌ها را نشان می‌دهد. همان‌طور که از شکل (۷) مشخص است بالاترین دقت سراسری مربوط به روش پیشنهادی اول با دقت ۹۸٫۵ درصد و کمترین دقت سراسری مربوط به روش تجزیه و نزیل با دقت سراسری ۸۱٫۱۵ درصد می‌باشد. همچنین به ازای دقت میانگین نیز استفاده از روش‌های پیشنهادی درصدی بالاتر از استفاده از تمامی ویژگی‌ها دارا می‌باشد. این افزایش ویژگی را نیز این‌گونه بیان کرد که با کاهش ابعاد می‌توان مسئله طبقه‌بندی را به فضای با ابعاد کمتر نگاشت داد به گونه‌ای که در فضای با ابعاد پایین‌تر با دقت بالاتری می‌توانیم مسئله جداسازی و کلاس‌بندی بین نمونه‌ها را حل نماییم. در این شکل نیز مشخص است که دقت سراسری به ازای روش پیشنهادی دوم در رتبه دوم با درصد ۹۷٫۶۴ درصد قرار گرفته و همچنین زیر هم چیدن ویژگی‌ها باز هم منجر به افزایش دقت شده است که البته مشخص است که این زیرهم چیدن منجر به دست‌یابی به بهینه‌ترین دقت نمی‌گردد. همچنین شکل (۸) نشان‌دهنده ضریب کاپا به‌ازای روش‌های پیشنهادی و سایر روش‌ها را نشان می‌دهد. این شکل نشان می‌دهد که علاوه بر اینکه روش‌های پیشنهادی دارای ضرایب کاپای بیشتری نسبت به سایر روش‌ها بوده‌اند همچنین، استفاده از مجموعه ویژگی‌ها (Stack) در کنار روش‌های پیشنهادی با اختلاف دارای ضرایب کاپای بهتری نسبت به سایر روش‌ها می‌باشند. علاوه براین، شکل (۹) نشان‌دهنده مقدار نرمالیزه شده اطلاعات متقابل [۴۲] به‌دست آمده بین ویژگی‌ها و نقشه طبقه‌بندی اولیه را نشان می‌دهد که ردیف افقی نشان‌دهنده شماره ویژگی است و ردیف عمودی میزان اطلاعات متقابل را نشان می‌دهد. نام ویژگی متناظر با شماره آن در جدول (۲) نشان داده شده است. در روش‌های پیشنهادی به‌منظور به‌دست‌آوردن ویژگی‌های بهینه از اطلاعات متقابل بین ویژگی‌های استخراج شده و نقشه طبقه‌بندی اولیه به‌منظور رتبه‌بندی ویژگی‌ها استفاده خواهیم کرد. بدین صورت که هر ویژگی دارای مقدار اطلاعات متقابل

شده که در قسمت شرح داده شد به عنوان ویژگی برتر بر طبق روش پیشنهادی معرفی شدند. همچنین، ۴۱ ویژگی حذف شده با استفاده از روش اول در جدول ۶ قابل مشاهده هستند. همچنین روش پیشنهادی دوم با دقت سراسری ۹۷٫۱۷، دقت میانگین ۹۷٫۶۴ و ضریب کاپای ۰٫۹۷۶ در جایگاه دوم قرار گرفته است. در این روش ۴۳ ویژگی به عنوان ویژگی بهینه انتخاب شده است که این ویژگی‌ها در جدول ۷ قابل مشاهده هستند. همان‌طور که از جدول ۵ مشخص است، رتبه سوم دقت به مجموعه همه ویژگی‌ها با دقت سراسری ۹۵٫۴۲، دقت میانگین ۹۶٫۱۴ و ضریب کاپای ۰٫۹۵۵ متعلق است و این جایگاه اثبات می‌کند که اگر از همه ویژگی‌های استخراج شده برای طبقه‌بندی تصاویر قطبی رادار دهانه مصنوعی استفاده کنیم به دقت طبقه‌بندی بهینه دست پیدا خواهیم کرد به گونه‌ای که روش پیشنهادی اول با انتخاب تنها ۶۱ ویژگی از همه ۱۰۳ ویژگی ممکن به دقت بالای ۹۸ درصد دست یافته که نشان‌دهنده این است که کاهش ویژگی‌ها و انتخاب ویژگی‌های بهینه منجر به افزایش دقت طبقه‌بندی شده است. علاوه بر این می‌توان رتبه‌بندی نهایی بر اساس دقت سراسری روش‌های پیشنهادی را به صورت شکل ۶ بیان کرد. این شکل نشان می‌دهد که روش پیشنهادی اول با دقت سراسری بالای ۹۸ درصد بهترین نتیجه طبقه‌بندی را دارا می‌باشد. همچنین روی پیشنهادی دوم با دقتی بالای ۹۷ درصدی به جایگاه دوم دست یافته است و در میان همه روش‌ها استفاده از تجزیه وینزل با دقت نزدیک به ۸۰ درصد پایین‌ترین دقت طبقه‌بندی را شامل می‌شود. همچنین این شکل نشان می‌دهد که زیرهم چیدن ویژگی‌ها (Stack و Stack TD) منجر به افزایش دقت طبقه‌بندی شده است. بدین معنا که اگر از همه ویژگی‌های استخراج شده به منظور طبقه‌بندی تصاویر استفاده نماییم دقت بالاتری نسب به زمانی که فقط از تک تک ویژگی‌ها برای طبقه‌بندی استفاده نماییم، دست خواهیم یافت.



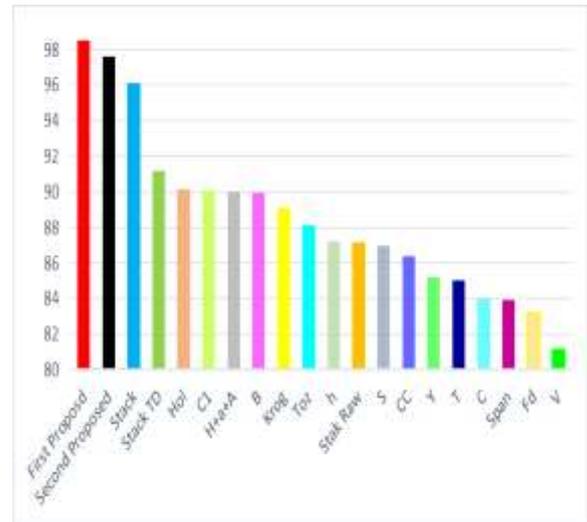
شکل (۶). مقایسه دقت سراسری بین روش‌ها



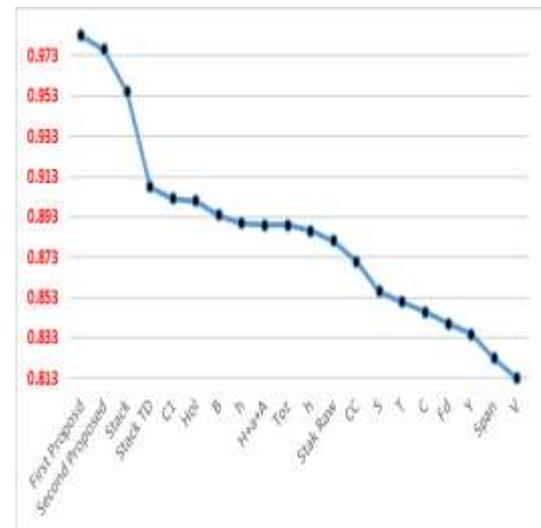
شکل (۹). مقدار نرمالیزه شده اطلاعات متقابل به دست آمده بین ویژگی‌ها و نقشه طبقه‌بندی اولیه

شکل (۱۰) نشان‌دهنده پنجاه ویژگی برتر از نظر معیار اطلاعات متقابل می‌باشد. در این شکل ردیف افقی نشان‌دهنده شماره ویژگی با ستون نارنجی‌رنگ و همچنین مقدار نرمالیزه شده اطلاعات متقابل مربوط به هر ویژگی با ستون آبی‌رنگ می‌باشد. در این شکل مشخص است که ویژگی شماره ۸۹ با مقدار اطلاعات متقابل بیشتر از ۰,۹۷، بهترین رتبه را در میان ویژگی‌ها بر اساس معیار اطلاعات متقابل دارا می‌باشد و جایگاه دوم متعلق به ویژگی اول بوده است. به همین ترتیب جایگاه پنجاهم متعلق به ویژگی شماره ۷۵ و با اطلاعات متقابل حدوداً ۰,۵ می‌باشد. همچنین رتبه سایر ویژگی‌های برتر در این شکل قابل مشاهده است. همچنین، شکل شماره (۱۱) نیز دقت سراسری به دست آمده در ۱۰۳ مرحله اجزای روش پیشنهادی اول را نشان می‌دهد. همان‌طور که از شکل (۱۱) مشخص است، ویژگی با رتبه اول (ویژگی شماره ۸۹) به تنهایی دارای دقت سراسری حدود ۸۵,۵ درصد می‌باشد و با افزایش تعداد ویژگی‌ها به ترتیب رتبه، دقت طبقه‌بندی به صورت صعودی افزایش می‌یابد. در این شکل ستون‌های هم‌ارتفاع نشان‌دهنده عدم افزایش دقت نسبت به مرحله قبل بوده و این امر منجر به حذف آن ویژگی شده است. همان‌طور که مشخص است، هر چه رتبه ویژگی به سمت بدتر شدن میل پیدا کرده است تعداد ستون‌های هم‌ارتفاع بیشتر شده است و نشان‌دهنده این است که ویژگی‌ها با رتبه کمتر معمولاً منجر به افزایش دقت طبقه‌بندی نشده و از مجموعه ویژگی‌ها کنار می‌روند. در این شکل، پس از ۱۰۳ مرحله به دقت سراسری بالای ۹۸ درصد دست‌یافته‌ایم. همان‌طور که از شکل (۱۱) مشخص است، با افزودن ۱۲ ویژگی برتر دقت طبقه‌بندی از میزان ۸۶,۱۶ درصد به ۸۷,۹۹ درصد افزایش پیدا می‌کند، اما با

بیشتری باشد دارای رتبه بالاتری نسبت به ویژگی است که مقدار اطلاعات متقابل آن کمتر است. این رتبه‌بندی را می‌توان این‌گونه بیان کرد که هر چه اطلاعات متقابل بین ویژگی‌ها و نقشه طبقه‌بندی اولیه بیشتر باشد، ویژگی مذکور دارای اطلاعات بیشتری نسبت به اهداف بوده و برای رسیدن به نرخ طبقه‌بندی بهینه می‌تواند مفیدتر از ویژگی‌هایی باشد که مقدار اطلاعات متقابل کمتری هستند. لذا، می‌توان از ویژگی مذکور به عنوان ویژگی بهینه در راستای رسیدن به دقت طبقه‌بندی بهینه استفاده نماییم. بنابراین، در روش‌های پیشنهادی ما اگر ویژگی دارای رتبه بالاتری باشد بدین معناست که اطلاعات بیشتری از نقشه طبقه‌بندی داراست و در نهایت با انتخاب کردن بهترین ویژگی‌ها بر اساس رتبه آنها به بهینه‌ترین نرخ طبقه‌بندی دست پیدا خواهیم کرد.



شکل (۷). مقایسه دقت میانگین برای روش پیشنهادی اول، دوم و سایرین

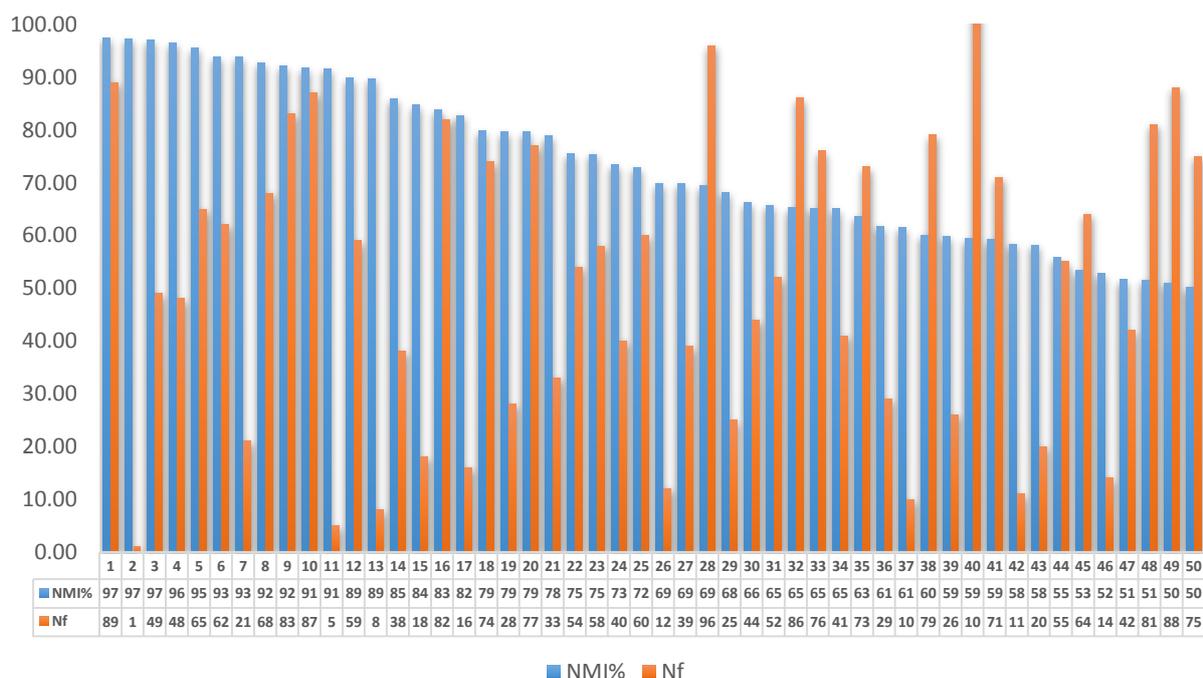


شکل (۸). مقایسه ضریب کاپا برای روش پیشنهادی اول، دوم و سایرین

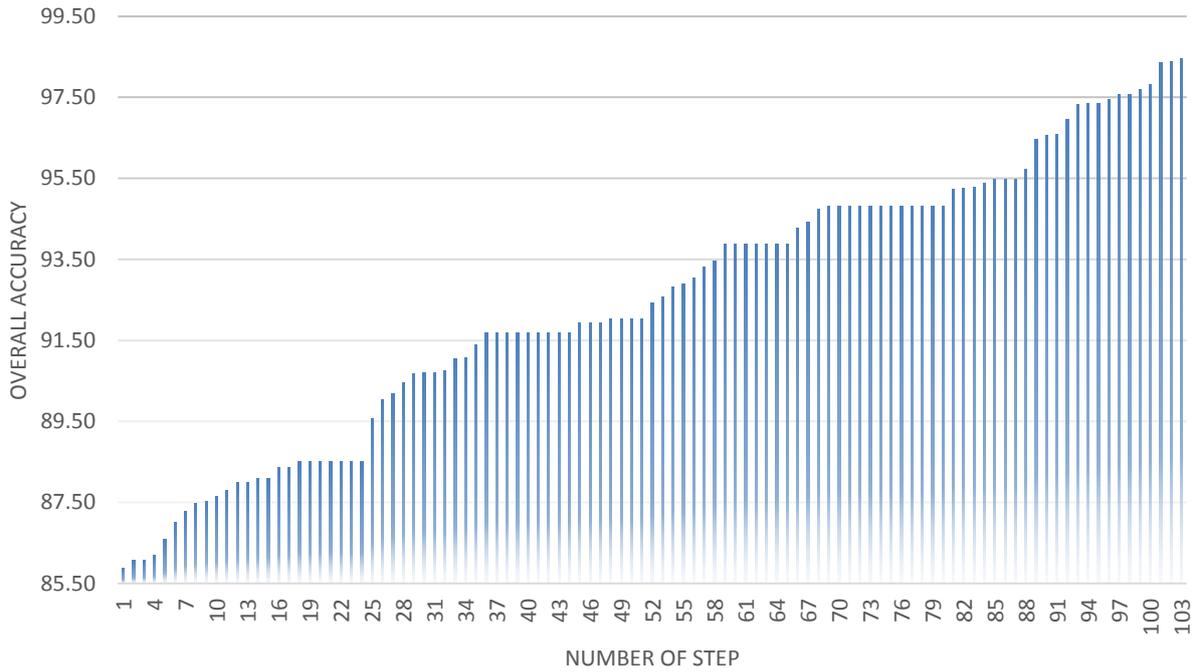
در غیر این صورت ویژگی در مجموعه باقی می‌ماند. همان‌طور که در شکل (۱۳) مشخص است در گام دوم و با حذف ویژگی با رتبه ۱۰۳ دقت طبقه‌بندی افزایش داشته است بنابراین، این ویژگی از مجموعه حذف می‌گردد. این روال تا گام چهاردهم و حذف ویژگی با رتبه ۹۰ ادامه داشته به گونه‌ای که با حذف ویژگی با رتبه ۱۰۳ تا ۹۰ دقت طبقه‌بندی به ۹۶٫۳۷ درصد افزایش می‌یابد و پس از آن با حذف ویژگی شماره ۸۹ افزایش دقتی نداریم که در شکل (۱۳) با ستون‌های هم ارتفاع نمایان هستند و بنابراین ویژگی با رتبه ۸۹ از مجموعه کنار گذاشته نمی‌شوند. به همین ترتیب ویژگی شماره ۸۸-۸۵ در مجموعه باقی می‌مانند و در ادامه حذف ویژگی‌ها با رتبه ۸۴-۷۰ و به روش پیشنهادی منجر به افزایش دقت طبقه‌بندی شده است لذا این ویژگی‌ها از مجموعه ویژگی‌ها کنار گذاشته می‌شوند. به دلیل مشابه ویژگی‌های شماره ۶۱-۴۸، ۴۳-۳۹، ۳۶، ۳۴-۳۲، ۳۰-۲۸، ۲۰-۱۸، ۱۱ و ۶ نیز از مجموعه ویژگی‌ها کنار می‌روند. در نهایت با ۴۳ ویژگی باقی‌مانده در این روش به دقت ۹۷٫۶۷ درصد دست پیدا کرده‌ایم. همان‌طور که مشخص است از ۱۰ ویژگی برتر فقط ویژگی با رتبه ششم در مجموعه ویژگی باقی نمی‌ماند که نشان‌دهنده این نکته است ویژگی‌ها با رتبه بالا از اهمیت بالایی در هر دو روش پیشنهادی برخوردار هستند. در نهایت، شماره ویژگی‌های باقی‌مانده در این روش در جدول (۷) قابل مشاهده است.

افزودن ویژگی با رتبه ۱۳ دقت طبقه‌بندی افزایشی نداشته است بنابراین، باتوجه به روش پیشنهادی اول، این ویژگی از مجموعه حذف می‌گردد. در ادامه ویژگی ۱۴ با افزایش دقت همراه بوده ولی ویژگی شماره ۱۵ افزایش دقتی نداشته لذا ویژگی رتبه ۱۵ نیز از مجموعه کنار می‌رود. به همین ترتیب ویژگی‌ها با رتبه‌های ۱۷، ۱۹-۲۴، ۳۷-۴۷، ۴۹-۵۱، ۶۱-۶۵، ۷۰-۷۹، ۸۶-۸۷، ۹۵ از مجموعه کنار گذاشته می‌شوند. بدین ترتیب مجموعه ۶۱ ویژگی که شامل بهترین ویژگی‌ها بوده در مجموعه ویژگی نهایی باقی‌مانده خواهد شد. همچنین، شکل (۱۲) رتبه‌بندی ویژگی‌ها را نشان می‌دهد. محور افقی رتبه ویژگی را نشان می‌دهد و محور عمودی نیز بیانگر شماره ویژگی متناظر آن است. همچنین در روش پیشنهادی اول، ویژگی‌های حذف‌شده مطابق با جدول (۶) می‌باشد. مطابق با این جدول ۴۱ ویژگی از مجموعه کنار رفته و با ۶۱ ویژگی باقی‌مانده به دقت طبقه‌بندی ۹۸٫۴۷ درصد دست پیدا کرده‌ایم که نرخ بالاتری نسبت به زمانی است که از تمامی ویژگی‌ها برای طبقه‌بندی استفاده خواهد شد.

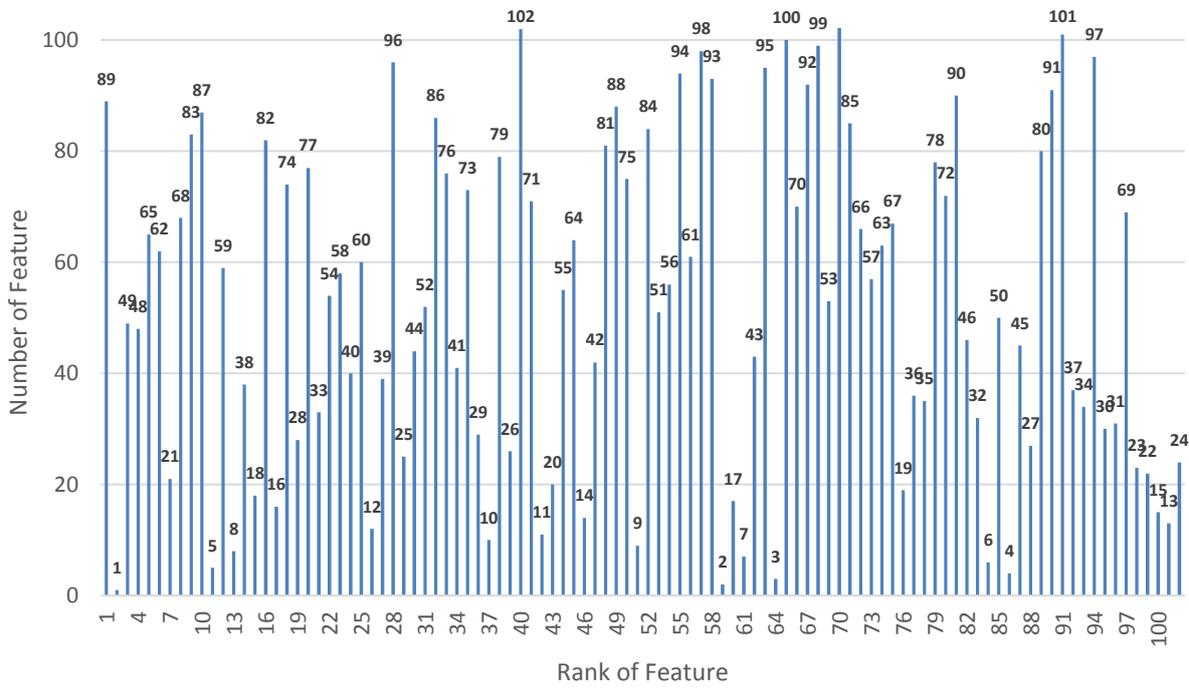
همچنین شکل (۱۳)، دقت سراسری در هر گام در روش پیشنهادی دوم را نشان می‌دهد. در این شکل در گام اول که تمامی ۱۰۳ ویژگی در مجموعه ویژگی‌ها حضور دارند دقت طبقه‌بندی مطابق جدول ۵، ۹۶٫۱ درصد می‌باشد. در هر گام مطابق با روش دوم تشریح داده شده، در صورتی که با حذف بدترین ویژگی‌ها دقت افزایش داشته باشد ویژگی مذکور حذف و



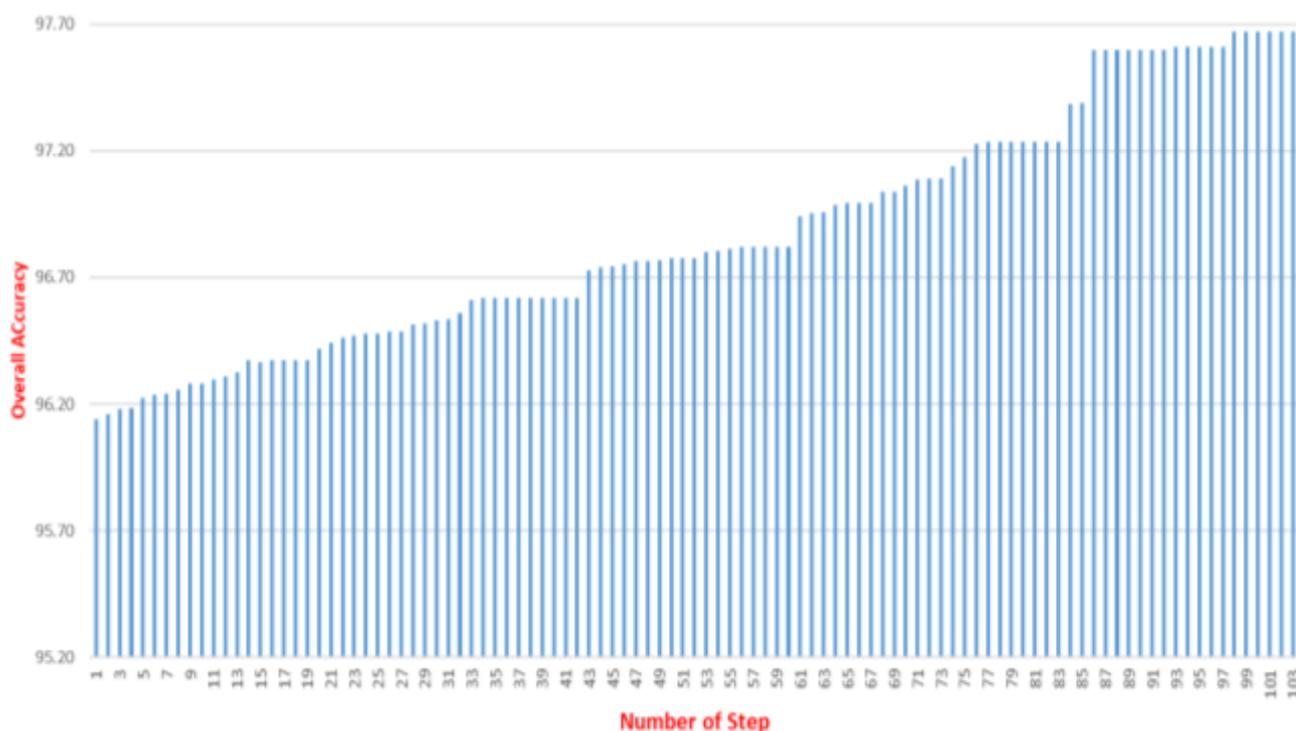
شکل (۱۰). پنجاه ویژگی برتر از نظر معیار اطلاعات متقابل



شکل (۱۱). دقت سراسری بدست آمده در ۱۰۳ مرحله اجرای روش پیشنهادی اول



شکل (۱۲). رتبه بندی ویژگی‌ها



شکل (۱۳). دقت سراسری در هر گام از روش پیشنهادی دوم

جدول (۶). ویژگی‌های حذف‌شده در روش پیشنهادی اول. Num_f نشان‌دهنده شماره ویژگی است.

Num_f	۸	۸۸	۱۶	۹	۷۷	۴۳	۵۴	۳	۴۰	۱۰۲	۷۹	۶۶	۱۰۱	۶۳	۱۱	۱۹	۵۵
Num_f	۱۸	۷۵	۲۸	۷	۳۳	۹۵	۵۸	۱۰۰	۱۰	۸۵	۲۶	۵۷	۷۱	۶۷	۲۰	۳۶	۶۴
Num_f	۳۵	۱۴	۴	۳۰	۷۸	۴۲	۴۵										

جدول (۷). ویژگی‌های باقی‌مانده در روش پیشنهادی دوم. Num_f نشان‌دهنده شماره ویژگی است.

Num_f	۸۰	۲۷	۴۵	۴	۵۰	۵۳	۹۹	۹۲	۷۰	۱۰۰	۳	۹۵	۴۳	۴۲	۱۴	۶۴	۵۵
Num_f	۱۰	۷۹	۷۳	۸۶	۳۹	۱۲	۶۰	۴۰	۵۸	۵۴	۳۳	۱۶	۸۲	۱۸	۳۸	۸	۵۹
Num_f	۸۷	۸۳	۸۶	۲۱	۶۲	۴۸	۴۹	۱	۸۹								

ترتیب برای کلاس‌های «چغندر، گندم، لوبیای بخار، سیب‌زمینی، آب، جنگل، چمن، خاک، لوسرن، نخودفرنگی و کلزا» می‌باشد. همچنین نمونه‌های کلاس «نخودفرنگی» ۳۳۸ بار به اشتباه وارد کلاس‌های دیگر شده‌اند که منجر به خطای طبقه‌بندی برای سایر کلاس‌ها شده‌اند. همچنین نمونه‌های کلاس «آب» نیز ۳۲۶ بار سایر کلاس‌ها را به اشتباه انداخته و از این حیث در جایگاه دوم قرار گرفته است. این

مقدار برای کلاس‌های «چغندر، لوسرن، خاک، کلزا، لوبیای بخار، سیب‌زمینی، چمن، گندم و جنگل» به ترتیب: ۲۵۳، ۲۹۲، ۱۷۸، ۷۸، ۱۰۰، ۱۶۶، ۸۸، ۲۹۷ و ۲۶۹ می‌باشد. مشخص است که کلاس «کلزا» کمترین میزان نمونه را در میان سایر کلاس‌ها

جدول (۸) نشان‌دهنده ماتریس خطا برای روش پیشنهادی اول می‌باشد، همان‌طور که این جدول، مشخص است، دقت به‌دست‌آمده در تمامی کلاس‌ها بالای ۹۸ درصد می‌باشد و فقط دو کلاس «کلزا» و «نخودفرنگی» دارای دقت ۹۵٫۸ درصد و ۹۶٫۲۷ درصد می‌باشند و این موضوع نشان‌دهنده برتری روش پیشنهادی می‌باشد. همچنین کلاس «چغندر» دارای دقت نزدیک به ۱۰۰ درصد می‌باشد به گونه‌ای که همه نمونه‌های این کلاس به‌صورت درست دسته‌بندی شده‌اند و فقط ۵ نمونه از آن وارد کلاس «جنگل» شده است. در این جدول مشخص است که پنج کلاس «چغندر، لوبیای بخار، سیب‌زمینی، آب و گندم» دارای دقت بالای ۹۹ درصد هستند. همچنین بیشترین دقت کلاس‌ها به

از میانگین کلاسی بالاتر می‌باشد. در این روش نیز کلاس «لوبیای بخار» ۱۲۴۵ بار سایر کلاس‌ها را به‌اشتباه انداخته است که بیشترین میزان می‌باشد. رتبه دوم نیز در اختیار کلاس «کلزا» با ۷۰۱ نمونه می‌باشد و همچنین کمترین مقدار برای کلاس «سیب‌زمینی» با تنها ۱۷۳ نمونه می‌باشد.

داراست. علاوه بر این، جدول ۹ نشان‌دهنده ماتریس خطا برای روش پیشنهادی دوم می‌باشد، همان‌طور که از این جدول، مشخص است، تمامی کلاس‌ها دارای دقتی بالاتر از ۹۶ درصد را دارا می‌باشند به جز کلاس‌های «کلزا» و «چمن» که دقت ۹۵٫۸ درصد و ۹۲٫۸۲ درصد را دارند. علاوه بر این، بازهم کلاس «چغندر» با دقت ۹۹٫۵۸ درصد بهترین نتیجه طبقه‌بندی را دارا می‌باشد. در نهایت، کلاس‌های «جنگل، گندم، آب، لوبیای بخار و چغندر» دارای دقت بالای ۹۸ درصد بوده و دقت طبقه‌بندی آنها

نام کلاس	چغندر	لوسرن	خاک	کلزا	لوبیای بخار	سیب‌زمینی	آب	چمن	نخودفرنگی	گندم	جنگل	دقت
چغندر	۱۱۷۶۷	۰	۰	۰	۰	۰	۰	۰	۰	۰	۵	۹۹٫۹۸
لوسرن	۳۳	۹۰۵۶	۰	۱	۱۴	۲۰	۴۰	۵۵	۴۳	۰	۰	۹۸٫۰۶
خاک	۳۳	۱۴	۱۶۰۶۲	۰	۴۲	۲	۳۶	۱	۲	۱	۱۴۰	۹۸٫۶۶
کلزا	۱۶۵	۲۳۶	۰	۲۶۰۱	۱۷	۲۰	۱۹۱	۲	۲۸۲	۲	۷۰	۹۵٫۸۱
لوبیای بخار	۰	۰	۰	۰	۱۴۲۶۶	۰	۰	۰	۰	۰	۰	۹۹٫۵۸
سیب‌زمینی	۷	۲۵	۲۱	۰	۰	۷۳۰۲۱	۰	۰	۴	۰	۷	۹۹٫۴۴
آب	۳	۱۴	۲۴	۸	۹	۶	۲۹۵۹۵	۰	۲	۰	۰	۹۹٫۲۲
چمن	۰	۰	۲۲	۰	۰	۵۲	۰	۹۲۵۲	۰	۰	۰	۹۸٫۸۲
نخودفرنگی	۹	۳	۱	۹	۹	۹	۴	۲۰	۱۳۳۷۲	۲۳۵	۱۱	۹۶٫۲۷
گندم	۰	۰	۶	۵	۰	۵۴	۳۶	۷	۵	۶۰۳۰۰	۳۶	۹۹٫۷۸
جنگل	۳	۰	۱۰۴	۴۷	۹	۳	۱۹	۳	۰	۵۹	۲۵۱۲۷	۹۸٫۸۷

جدول (۸). ماتریس خطا برای روش پیشنهادی اول

جدول (۹). ماتریس خطا برای روش پیشنهادی دوم

نام کلاس	چغندر	لوسرن	خاک	کلزا	لوبیای بخار	سیب‌زمینی	آب	چمن	نخودفرنگی	گندم	جنگل	دقت
چغندر	۱۱۷۲۲	۷	۱۰	۶	۶	۱	۰	۱۵	۱	۱	۵	۹۹٫۵۸
لوسرن	۳۳	۸۸۹۷	۰	۱	۱۴	۲	۴۰	۵۵	۴۳	۱۵۹	۰	۹۶٫۰۶
خاک	۳۳	۱۴	۱۵۸۳۸	۲۷۷	۴۲	۲	۳۶	۱	۲	۱	۱۴۰	۹۶٫۶۶
کلزا	۱۶۵	۲۳۶	۱۰۱	۲۵۰۰۰	۱۷	۲۰	۱۹۱	۲	۲۸۲	۲	۷۰	۹۵٫۸۱
لوبیای بخار	۱	۲	۸۸	۸	۱۴۰۶۹	۶	۱۰	۵۶	۱	۲	۱	۹۸٫۵۱
سیب‌زمینی	۷	۲۵	۲۱	۳۴۰	۴۷۳	۴۱۹۸۰	۰	۹۲	۴	۱۳۶	۷	۹۷٫۴۰
آب	۳	۱۴	۲۴	۸	۹	۶	۲۹۴۳۲	۱۰۳	۲	۶۰	۰	۹۹٫۲۰
چمن	۷۸	۱۰۵	۲۲	۰	۸۶	۵۲	۲۶۳	۸۶۵۶	۰	۲۴	۱۰	۹۲٫۸۲
نخودفرنگی	۹	۳	۱	۹	۹	۹	۴۰	۲۰	۱۳۱۷۲	۴۳۵	۱۱	۹۶٫۲۷
گندم	۳۲۶	۱۰۳	۶	۵	۵۸۰	۵۴	۳۶	۷	۵	۵۹۲۹۱	۳۶	۹۸٫۰۸
جنگل	۳	۰	۱۰۴	۴۷	۹	۳	۱۹	۳	۰	۶۰	۲۵۱۲۶	۹۸٫۸۵

ویژگی‌ها، زیر هم چیدن ویژگی‌های تجزیه هدف، زیر هم چیدن ویژگی‌های مستقیم به‌دست‌آمده، تجزیه کاروگر، تجزیه هیونین، تجزیه بارانس، تجزیه کلد، تجزیه هولم، تجزیه ونزیل، تجزیه کلد-پیتر، تجزیه فریمن، تجزیه یامگونچی و تجزیه توزی می‌باشد. در این جدول رنگ قرمز نشان‌دهنده رتبه اول و رنگ بنفش نشان-

جدول (۱۰)، نشان‌دهنده دقت به‌دست‌آمده توسط روش‌های مختلف برای کلاس‌های مختلف دادگان می‌باشد. در این جدول، P1 نشان‌دهنده روش پیشنهادی اول، P2 روش پیشنهادی دوم و همچنین Stack, STD, SR, K, H, B, C1, Hol, H+A, V, Fd, Y و Toz به ترتیب نشان‌دهنده روش زیر هم چیدن تمامی

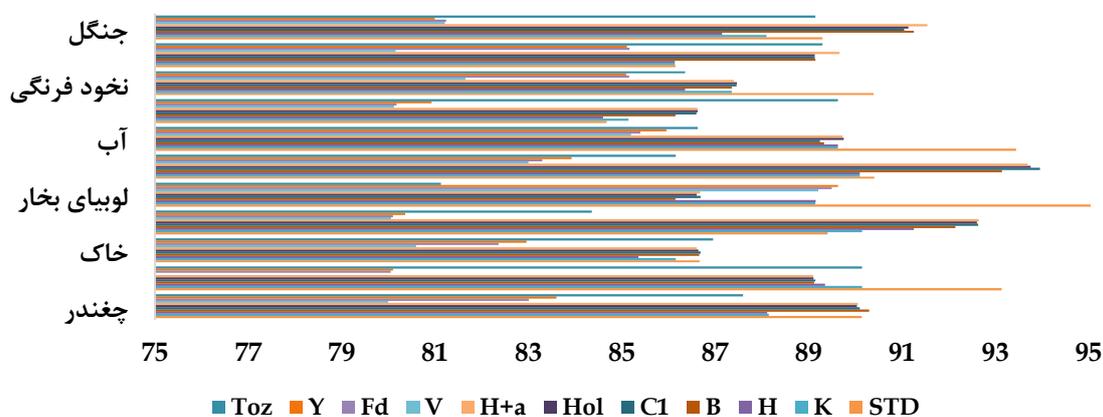
کلاس «لوبیای بخار» که دارای دقت ۸۹٫۲۱ درصد می‌باشد، تمامی کلاس‌ها دارای دقت کمتر ۸۵ درصد هستند. همچنین بدترین دقت طبقه‌بندی در میان همه روش‌ها و کلاس‌ها متعلق به کلاس «لوسرن» و روش تجزیه و تنزیل بادقت ۷۰٫۶۲ درصد می‌باشد. همچنین شکل (۱۴)، دقت به‌دست‌آمده برای روش‌های مختلف تجزیه هدف را نشان می‌دهد. همان‌طور که از این شکل مشخص است استفاده از همه ویژگی‌ها در کنار هم یعنی روش STD در همه کلاس‌ها منجر به بهبود نتایج شده است، به‌گونه‌ای که در سه کلاس «لوسرن، لوبیای بخار و آب» استفاده از روش STD دقت به‌دست‌آمده با اختلاف نسبت به سایر کلاس‌ها بالاتر می‌باشد.

دهنده رتبه دوم دقت می‌باشد. با توجه به جدول مشخص است که روش پیشنهادی در همه کلاس‌ها دارای رتبه اول و روش پیشنهادی دوم نیز در دو کلاس «کلزا» و «نخودفرنگی» دارای رتبه اول و در سایر کلاس‌ها دارای رتبه دوم می‌باشد. علاوه بر این، روش زیر هم چیدن ویژگی‌ها دارای رتبه سوم بوده و فقط در کلاس «کلزا» دارای رتبه دوم می‌باشد.

این روش نسبت به سایر روش‌ها دارای دقت بالاتری بوده؛ اما در مقابل با روش‌های پیشنهادی به جز کلاس «کلزا» از جایگاه پایین‌تری برخوردار است. همچنین مشخص است که بدترین دقت طبقه‌بندی متعلق به روش تجزیه وینزل می‌باشد که در جدول با رنگ صورتی مشخص شده است. در این روش به‌جز

نماد روش / نام کلاس	P1	P2	Stack	STD	K	H	B	C1	Hol	H+a	V	Fd	Y	Toz
چغندر	۹۹٫۹۸	۹۹٫۵۸	۹۹٫۴۱	۹۰٫۱۴	۸۸٫۱۵	۸۲٫۱۲	۹۰٫۳۱	۹۰٫۱۲	۹۰٫۰۴	۹۰٫۰۶	۸۰٫۲۱	۸۳٫۰۱	۸۳٫۶۱	۸۷٫۶۱
لوسرن	۹۸٫۰۶	۹۶٫۰۶	۹۵٫۳۴	۹۳٫۱۴	۹۰٫۱۵	۸۹٫۳۶	۸۹٫۱۲	۸۹٫۱۵	۸۹٫۱۱	۸۹٫۱۲	۷۰٫۶۲	۸۰٫۰۵	۸۰٫۱۰	۹۵٫۱۲
خاک	۹۸٫۶۶	۹۶٫۶۶	۹۰٫۱۲	۸۶٫۶۷	۸۶٫۱۶	۸۵٫۳۶	۸۶٫۶۶	۸۶٫۶۹	۸۶٫۶۴	۸۶٫۶۱	۸۰٫۶۲	۸۲٫۳۶	۸۲٫۹۶	۸۶٫۹۶
کلزا	۹۵٫۸۲	۹۵٫۸۲	۹۵٫۸۱	۸۹٫۴۱	۹۰٫۱۵	۹۱٫۲۶	۹۲٫۱۵	۹۲٫۶۴	۹۲٫۶۱	۹۲٫۶۵	۸۰٫۰۶	۸۰٫۱۲	۸۰٫۳۶	۸۴٫۳۶
لوبیای بخار	۹۹٫۵۸	۹۸٫۵۱	۹۸٫۳۶	۹۸٫۳۶	۸۹٫۱۵	۸۹٫۱۶	۸۶٫۱۵	۸۶٫۶۹	۸۶٫۶۱	۸۶٫۶۸	۸۹٫۲۱	۸۹٫۵۱	۸۶٫۶۳	۸۱٫۱۳
سیب‌زمینی	۹۹٫۴۱	۹۷٫۴۰	۹۶٫۵۴	۹۰٫۴۱	۹۰٫۱۳	۹۰٫۱۲	۹۳٫۱۵	۹۳٫۹۶	۹۳٫۷۶	۹۳٫۷۱	۸۳٫۰۱	۸۳٫۳۱	۸۳٫۹۳	۸۶٫۱۶
آب	۹۹٫۲۲	۹۹٫۲۱	۹۵٫۱۵	۹۳٫۴۲	۸۹٫۶۳	۸۹٫۶۳	۸۹٫۳۴	۸۹٫۲۵	۸۹٫۷۳	۸۷٫۷۳	۸۵٫۲۱	۸۵٫۴۱	۸۵٫۹۶	۸۶٫۶۳
چمن	۹۸٫۸۲	۹۲٫۸۳	۸۹٫۱۶	۸۴٫۶۲	۸۵٫۱۵	۸۴٫۶۱	۸۶٫۱۵	۸۶٫۶۲	۸۶٫۶۲	۸۶٫۶۱	۸۰٫۱۲	۸۰٫۱۸	۸۹٫۹۳	۸۹٫۶۲
نخودفرنگی	۹۶٫۲۷	۹۶٫۲۷	۹۶٫۲۷	۹۰٫۴۱	۸۷٫۳۶	۸۶٫۳۸	۸۷٫۳۶	۸۷٫۴۶	۸۷٫۴۷	۸۷٫۴۱	۸۱٫۶۲	۸۵٫۱۶	۸۵٫۱	۸۶٫۳۶
گندم	۹۹٫۷۸	۹۸٫۰۸	۹۴٫۱۵	۸۶٫۱۵	۸۶٫۱۴	۸۶٫۱۴	۸۹٫۱۵	۸۹٫۱۳	۸۹٫۱۴	۸۹٫۶۷	۸۰٫۱۶	۸۵٫۱۷	۸۵٫۱۱	۸۹٫۳۱
جنگل	۹۸٫۸۷	۹۸٫۸۵	۹۸٫۳۱	۸۹٫۳۱	۸۸٫۱۲	۸۷٫۱۵	۹۱٫۲۶	۹۱٫۰۵	۹۱٫۱۴	۹۱٫۵۵	۸۱٫۲۱	۸۱٫۲۴	۸۱٫۰۴	۸۹٫۱۵

جدول (۱۰). محاسبه دقت به تفکیک کلاس و روش‌های مختلف



شکل (۱۴). دقت به‌دست‌آمده برای روش‌های تجزیه هدف

جدول (۵). نتایج حاصل از آزمایش‌ها

نوع ویژگی	نماد	تعداد ویژگی	دقت سراسری	دقت میانگین	ضریب کاپا
ویژگی‌های مستقیم	T	۹	۸۴,۱۵	۸۵,۰۴	۰,۸۵۱
	C	۹	۸۳,۵۶	۸۳,۹۶	۰,۸۴۱
	S	۹	۸۶,۴۹	۸۶,۹۷	۰,۸۵۶
انباشته کردن ویژگی‌های مستقیم	T+C+S	۲۱	۸۷,۱۵	۸۷,۱۹	۰,۸۸۱
ویژگی‌های تجزیه هدف	Krog	۹	۸۸,۱۵	۸۹,۱۴	۰,۸۸۶
	h	۹	۸۷,۵۴	۸۷,۲۵	۰,۸۸۹
	B	۹	۸۹,۴۸	۸۹,۹۶	۰,۸۸۴
	C1	۹	۸۹,۵۹	۹۰,۱۱	۰,۹۰۲
	Hol	۹	۸۹,۷۸	۹۰,۱۴	۰,۹۰۱
	V	۳	۸۰,۷۸	۸۱,۱۵	۰,۸۱۳
	H+a+α	۱۹	۸۹,۴۹	۹۰,۰۱	۰,۸۸۹
	Fd	۳	۸۳,۱۴	۸۳,۱۹	۰,۸۴۰
	Y	۴	۸۴,۹۲	۸۵,۱۹	۰,۸۳۵
	Toz	۴	۸۷,۶۹	۸۸,۱۵	۰,۸۹۱
	CC	۳	۸۶,۳۶	۸۶,۳۹	۰,۸۷۱
	Span	۱	۸۳,۱۵	۸۳,۹۰	۰,۸۲۳
	انباشته کردن ویژگی‌های تجزیه هدف	Krog+h+B+C1+Hol+V+H+a+α+ Fd+Y+Toz	۷۸	۹۰,۱۸	۹۱,۱۶
انباشته کردن کلیه ویژگی‌ها	T+C+S+ Krog+h+B+C1+Hol+V+H+a+α+ Fd+Y+Toz+CC+Span	۱۰۳	۹۵,۴۲	۹۶,۱۴	۰,۹۵۵
روش پیشنهادی اول	---	۶۱	۹۸,۴۶	۹۸,۵۱	۰,۹۸۳
روش پیشنهادی دوم	---	۴۳	۹۷,۱۷	۹۷,۶۴	۰,۹۷۶

شده است. ۳- استفاده از روش مبتنی بر شبکه عصبی کانولوشنال: در [29] نویسندگان با طراحی یک شبکه مبتنی بر شبکه عصبی کانولوشنال سعی در کاهش ویژگی‌های تصاویر راداری به منظور افزایش دقت طبقه‌بندی کرده‌اند. در جدول ۱۱ این روش با نماد $DCNN^3$ مشخص شده است. ۴- استفاده از شبکه عصبی مبتنی بر تکرار در [49] نویسندگان با طراحی یک شبکه مبتنی بر شبکه عصبی تکراری سعی در کاهش ویژگی‌های تصاویر راداری به منظور افزایش دقت طبقه‌بندی کرده‌اند. در جدول ۱۱ این روش با نماد $DRNN^4$ مشخص شده است. ۵- استفاده از یک شبکه خود نظارتی به منظور کاهش ویژگی‌ها: در [50] نویسندگان به منظور کاهش ویژگی‌ها و همچنین افزایش دقت طبقه‌بندی تصاویر راداری از یک روش خود نظارتی استفاده کرده‌اند. در جدول ۱۱ این روش با نماد SS^5 مشخص شده است.

۷-۱- مقایسه روش پیشنهادی با سایر روش‌ها

های موجود

به منظور مقایسه بهتر روش‌های پیشنهادی در ادامه به مقایسه روش‌های گفته شده با پنج روش جدید به منظور طبقه‌بندی تصاویر راداری خواهیم پرداخت. لازم به ذکر است که روش‌های گفته شده دارای بیشترین استناد در مقالات مختلف می‌باشند. در ادامه به بیان این روش‌ها خواهیم پرداخت. ۱- استفاده از روش رگرسیون خطی به منظور طبقه‌بندی تصاویر راداری: در [37] نویسندگان به منظور بهبود دقت طبقه‌بندی تصاویر راداری از یک تخمین‌گر خطی به منظور کاهش ویژگی‌های تصاویر راداری استفاده کرده‌اند. در جدول ۱۱ این روش با نماد LR^1 مشخص شده است. ۲- استفاده از گراف به منظور کاهش ویژگی: در [48] نویسندگان به منظور افزایش دقت طبقه‌بندی تصاویر راداری از روش مبتنی بر گراف ناحیه-ای بهره بردند. در جدول ۱۱ این روش با نماد LG^2 مشخص

³ Deep Convolutional Neural Networks

⁴ Deep Recurrent Neural Networks

⁵ Self-Supervised

¹ Linear Regression

² Local Graph

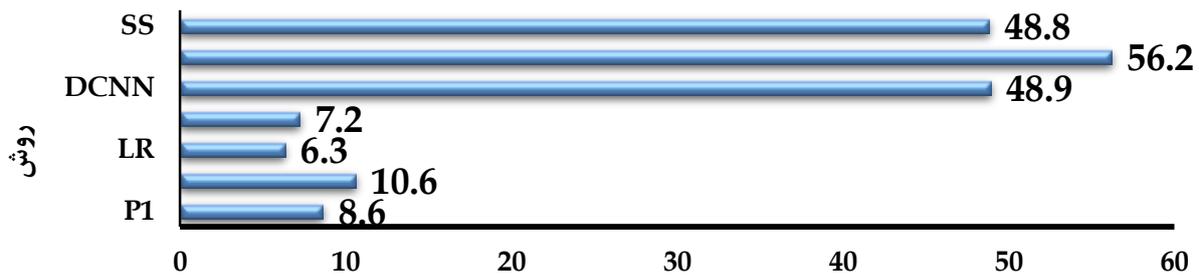
جدول (۱۱). مقایسه روش‌های پیشنهادی با سایر روش‌های رقیب

نام روش	نماد	دقت سراسری	دقت میانگین	ضریب کاپا
روش پیشنهادی اول	P1	۹۸,۴۶	۹۸,۵۱	۰,۹۸۱
روش پیشنهادی دوم	P2	۹۷,۱۷	۹۷,۶۴	۰,۹۷۲
رگرسیون خطی	LR	۹۴,۶۸	۹۴,۹۷	۰,۹۴۴
گراف ناحیه‌ای	LG	۹۵,۶۹	۹۴,۶۸	۰,۹۳۱
شبکه عصبی کانولوشنال عمیق	DCNN	۹۶,۶۷	۹۵,۶۳	۰,۹۴۵
شبکه عصبی تکراری عمیق	DRNN	۹۶,۹۷	۹۶,۱۷	۰,۹۲۱
شبکه خودآموزش	SS	۹۵,۶۵	۹۵,۲۱	۰,۹۳۵

های پیشنهادی با سایر روش‌ها نشان می‌دهد. همان‌طور که انتظار داشته‌ایم، روش‌های مبتنی بر شبکه عصبی از زمان اجرای بسیار زیادی برخوردار بوده و همچنین نسبت به روش‌های سنتی، روش‌های پیشنهادی در این مقاله از زمان اجرای قابل‌قبولی برخوردار است.

همان‌طور که از جدول ۱۱، مشخص است، روش‌های پیشنهادی در مقایسه با روش‌های رقیب دارای دقتی بالاتر می‌باشند که این موضوع نشان‌دهنده برتری روش پیشنهادی می‌باشد. همچنین در مقایسه با زمان اجرای فرایند، روش‌های پیشنهادی با پنج روش رقیب گفته شده مورد بررسی قرار گرفته است. شکل ۱۷ نشان‌دهنده زمان اجرای فرایند روش-

زمان اجرای فرایند روش پیشنهادی و سایر روش‌ها



زمان بر حسب دقیقه

شکل (۱۷). زمان اجرای فرایند روش‌های پیشنهادی و سایر روش‌ها.

ویژگی‌های استخراج شده و نقشه طبقه‌بندی اولیه به دست آورده شد و بر اساس بزرگی مقدار اطلاعات متقابل برای هر ویژگی رتبه خاصی در نظر گرفته شد. بدین صورت که هر کدام از ویژگی‌هایی که دارای مقدار اطلاعات متقابل بیشتری باشد دارای رتبه بالاتری نسبت به ویژگی‌هایی هستند که مقدار اطلاعات متقابل آنها کمتر است. این رتبه‌بندی را می‌توان این‌گونه بیان کرد که هر چه اطلاعات متقابل بین ویژگی‌ها و نقشه طبقه‌بندی اولیه بیشتر باشد، ویژگی‌های مذکور دارای اطلاعات بیشتری نسبت به اهداف بوده و برای رسیدن به نرخ طبقه‌بندی بهینه می‌تواند مفیدتر از ویژگی‌هایی باشند که مقدار اطلاعات متقابل کمتری دارا می‌باشند؛ لذا، بدین صورت و بر مبنای دو روش پیشنهادی، دودسته ویژگی خاص به‌عنوان ویژگی بهینه انتخاب شد. در روش پیشنهادی اول از میان ۱۰۳ ویژگی کلی به ۶۱ ویژگی بهینه دست یافتیم و در روش پیشنهادی دوم از میان ۱۰۳ ویژگی کلی به ۴۱ ویژگی بهینه دست یافتیم. همچنین نتایج آزمایش‌ها بر

۸- نتیجه‌گیری

طبقه‌بندی پوشش‌های زمینی با استفاده از تصاویر قطبی استخراج شده از رادار دهانه مصنوعی، همواره از موضوعات مهم و چالش‌برانگیز تحقیقاتی محققان بوده است. رسیدن به بهترین دقت در مسئله طبقه‌بندی اهداف در پوشش‌های مختلف سطح زمین نیازمند استفاده از ویژگی‌های مناسب استخراج شده از تصاویر قطبی رادار دهانه مصنوعی می‌باشد. در این مقاله سعی شد روشی بیان شود که نرخ طبقه‌بندی اهداف پوششی سطح زمین نسبت به روش‌های سنتی افزایش پیدا کند. بدین منظور دو روش پیشنهادی مختلف بیان شد که هدف هر دوی آنها به‌دست‌آوردن دسته‌ای بهینه از ویژگی‌های قطبی استخراج شده از تصاویر رادار دهانه مصنوعی به نحوی بود که نرخ طبقه‌بندی افزایش پیدا کند. در هر دو روش در ابتدا اطلاعات متقابل بین

- [11] Zhang, Yachao, Xuan Lai, Yuan Xie, Yanyun Qu, and Cuihua Li, "Geometry-Aware Discriminative Dictionary Learning for PolSAR Image Classification," In *Remote Sensing*, vol. 6, pp.12-18, 2021.
- [12] Chen, Yanqiao, Lingling Li, Licheng Jiao, Yangyang Li, Xu Liu, and Xinghua Chai, "Nonlinear Projective Dictionary Pair Learning for PolSAR Image Classification." In *IEEE Access*, vol. 9, pp. 70650-70661, 2021.
- [13] Kuo, Frances Y, and Ian H. Sloan, "Lifting the curse of dimensionality," In *Notices of the AMS*, vol. 11, pp. 1320-1328, 2005.
- [14] Salehi M., Y. Maghsoudi, and M. R. Sahebi, "Improving the Urban Area Classification Using Radar Polarimetric Data and multiobjective optimization methods," In *Journal of Radar*, vol. 1, pp. 45-56, 2014 (in Persian).
- [15] Maghsoudi, Yasser, Michael Collins, and Donald G. Leckie, "Polarimetric classification of Boreal forest using nonparametric feature selection and multiple classifiers," In *International journal of applied earth observation and geoinformation*, vol. 19, pp. 139-150, 2012.
- [16] Dabbiru, Lalitha, Sathishkumar Samiappan, Rodrigo AA Nobrega, James A. Aanstoos, Nicolas H. Younan, and Robert J. Moorhead, "Fusion of synthetic aperture radar and hyperspectral imagery to detect impacts of oil spill in Gulf of Mexico," In *2015 IEEE international geoscience and remote sensing symposium (IGARSS)*, vol. 2, pp. 1901-1904, 2015.
- [17] Cao, Yice, Yan Wu, Ming Li, Wenkai Liang, and Peng Zhang, "PolSAR image classification using a superpixel-based composite kernel and elastic net," In *Remote Sensing*, vol. 3, pp.380-381, 2021.
- [18] Wang, Jianlong, Biao Hou, Licheng Jiao, and Shuang Wang, "Representative learning via span-based mutual information for PolSAR image classification," In *Remote Sensing*, vol. 9, pp.1609-1616, 2021.
- [19] Liu, Hongying, Derong Xu, Tianwen Zhu, Fanhua Shang, Yuanyuan Liu, Jianhua Lu, and Ri Yang, "Graph convolutional networks by architecture search for PolSAR image classification," In *Remote Sensing*, vol. 7, pp. 1404-1405, 2021.
- [20] Gui, Rong, Xin Xu, Rui Yang, Zhaozhuo Xu, Lei Wang, and Fangling Pu, "A general feature paradigm for unsupervised cross-domain PolSAR image classification," In *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5, 2021.
- [21] Zhang, Peng, Xiaofeng Tan, Beibei Li, Yinyin Jiang, Wanying Song, Ming Li, and Yan Wu, "PolSAR image classification using hybrid conditional random fields model based on complex-valued 3-D CNN," In *IEEE Transactions on Aerospace and Electronic Systems*, vol. 3, pp. 1713-1730, 2021.
- [22] Pottier, Eric, and J-S. Lee, "Application of the «H/A/alpha» polarimetric decomposition theorem for unsupervised classification of fully polarimetric SAR data based on the wishart distribution," In *SAR workshop: CEOS Committee on Earth Observation Satellites*, vol. 1, pp. 335, 2000.
- [23] Krogager, E, "Absolute phase of the radar target scattering matrix," In *Electronics Letters*, vol. 26, pp. 1834-1835, 1990.

روی داده راداری منطقه Flevoland نشان از برتری روش پیشنهادی در مقایسه با طبقه‌بندی با تمام ویژگی‌ها داشته است. به‌گونه‌ای که در روش پیشنهادی اول به‌دقت ۹۸,۴۶ درصد دست‌یافته و در روش پیشنهادی به‌دقت ۹۷,۱۷ درصد رسیده‌ایم که دقت هر دو روش بالاتر از هنگامی است که از مجموعه تمامی ویژگی‌ها برای طبقه‌بندی اهداف استفاده کرده باشیم.

۹- مراجع

- [1] Yang, Chen, Biao Hou, Jocelyn Chanussot, Yue Hu, Bo Ren, Shuang Wang, and Licheng Jiao, "N-Cluster Loss and Hard Sample Generative Deep Metric Learning for PolSAR Image Classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol.2, pp.205-207, 2021.
- [2] Okwuashi, Onuwa, Christopher E. Ndehedehe, Dupe Nihinlola Olayinka, Aniekan Eyoh, and Hosanna Attai, "Deep support vector machine for PolSAR image classification," In *International Journal of Remote Sensing*, vol. 42, pp. 6502-6540, 2021.
- [3] Liu, Guangyuan, Yangyang Li, Licheng Jiao, Yanqiao Chen, and Ronghua Shang, "Multiobjective evolutionary algorithm assisted stacked autoencoder for PolSAR image classification," In *Swarm and Evolutionary Computation*, vol.60, no.25, pp.100794, 2021.
- [4] Wang, Xiao, Lamei Zhang, Ning Wang, and Bin Zou, "Joint Polarimetric-Adjacent Features Based on LCSR for PolSAR Image Classification," In *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* vol.14, pp. 6230-6243, 2021.
- [5] Dong, Hongwei, Lamei Zhang, and Bin Zou, "Exploring vision transformers for polarimetric SAR image classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol.4, pp. 1-15, 2021.
- [6] Tsunoda, Stanley I., Frank Pace, Jesse Stence, Marv Woodring, William H. Hensley, Armin W. Doerry, and Bruce C. Walker, "Lynx: A high-resolution synthetic aperture radar," In *IEEE Aerospace Conference*, vol. 5, pp. 51-58, 2000.
- [7] Cui, Yuanhao, Fang Liu, Licheng Jiao, Yuwei Guo, Xuefeng Liang, Lingling Li, Shuyuan Yang, and Xiaoxue Qian, "Polarimetric multipath convolutional neural network for PolSAR image classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1-18, 2021.
- [8] Ban, Yifang, and Hongtao Hu, "RADARSAT fine-beam SAR data for land-cover mapping and change detection in the rural-urban fringe of the greater Toronto area," In *2007 Urban Remote Sensing Joint Event*, vol. 4, pp. 1-7, 2007.
- [9] McNairn, H., J. Ellis, J. J. Van Der Sanden, T. Hirose, and R. J. Brown, "Providing crop information using RADARSAT-1 and satellite optical imagery," In *International Journal of Remote Sensing*, vol. 5, pp. 851-870, 2002.
- [10] Morena, L. C., K. V. James, and J. Beck, "An introduction to the RADARSAT-2 mission," In *Canadian Journal of Remote Sensing*, vol. 3, pp. 221-234, 2004.

- "Distributions and characteristics of spike noise," In *Journal of magnetism and magnetic materials*, vol. 1, pp. 68-72, 2001.
- [37] Imani, Maryam, "Polarimetric SAR Classification Using Ridge Regression-Based Polarimetric-Spatial Feature Extraction," In *26th International Computer Conference, Computer Society of Iran (CSICC)*, pp.1-5 2021.
- [38] Lee, Jong-Sen, Mitchell R. Grunes, and Gianfranco De Grandi, "Polarimetric SAR speckle filtering and its implication for classification," In *IEEE Transactions on Geoscience and remote sensing*, vol.1 , pp. 2363-2373, 1999.
- [39] Park, Jooyoung, and Irwin W. Sandberg, "Approximation and radial-basis-function networks," In *Neural computation*, vol. 2, pp. 305-316, 1993.
- [40] Thielicke, William, and René Sonntag, "Particle Image Velocimetry for MATLAB: Accuracy and enhanced algorithms in PIVlab," In *Journal of Open Research Softwar*, vol. 1, pp.1-9, 2021.
- [41] Rigby, Alan S, "Statistical methods in epidemiology. v. Towards an understanding of the kappa coefficient," In *Disability and rehabilitation*, vol. 8, pp. 339-344, 2000.
- [42] Estévez, Pablo A., Michel Tesmer, Claudio A. Perez, and Jacek M. Zurada, "Normalized mutual information feature selection," In *IEEE Transactions on neural networks*, vol. 2, pp. 189-201, 2009.
- [43] Cheng, Jianda, Fan Zhang, Deliang Xiang, Qiang Yin, and Yongsheng Zhou, "PolSAR image classification with multiscale superpixel-based graph convolutional network." In *IEEE Transactions on Geoscience and Remote Sensing*, vol. 1, pp. 1-14, 2021.
- [44] Liu, Xu, Licheng Jiao, Xu Tang, Qigong Sun, and Dan Zhang, "Polarimetric convolutional network for PolSAR image classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol. 5, pp. 3040-3054, 2018.
- [45] Chen, Si-Wei, and Chen-Song Tao, "PolSAR image classification using polarimetric-feature-driven deep convolutional neural network," In *IEEE Geoscience and Remote Sensing Letters*, vol.1, pp.627-631, 2018.
- [46] Bi, Haixia, Feng Xu, Zhiqiang Wei, Yong Xue, and Zongben Xu, "An active deep learning approach for minimally supervised PolSAR image classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol. 11, pp. 9378-9395, 2019.
- [47] Li, Yangyang, Yanqiao Chen, Guangyuan Liu, and Licheng Jiao, "A novel deep fully convolutional network for PolSAR image classification," In *Remote Sensing* , vol.12, pp. 1984-1991, 2018.
- [48] Liao, Wenzhi, Mauro Dalla Mura, Jocelyn Chanussot, and Aleksandra Pižurica, "Fusion of spectral and spatial information for classification of remote-sensed imagery by local graph," In *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 2, pp. 583-594, 2015.
- [49] Mou, Lichao, Pedram Ghamisi, and Xiao Xiang Zhu, "Deep recurrent neural networks for image classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol. 7, pp. 3639-3655, 2017.
- [50] Dang, Bo, and Yansheng Li, "MSResNet: Multiscale residual network via self-supervised learning for water-body detection in remote sensing imagery," In *Remote Sensing*, vol. 16, pp. 3122-3129, 2021.
- [24] Pottier, Eric, and Laurent Ferro-Famil, "PolSARPro V5. 0: An ESA educational toolbox used for self-education in the field of POLSAR and POL-INSAR data analysis," In *IEEE International Geoscience and Remote Sensing Symposium*, vol. 1, pp.5-11, 2012.
- [25] Jiang, Yinyin, Ming Li, Peng Zhang, Xiaofeng Tan, and Wanying Song, "Unsupervised Complex-Valued Sparse Feature Learning for PolSAR Image Classification," In *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp.1-16, 2022.
- [26] Xie, Wen, Licheng Jiao, and Wenqiang Hua, "Complex-Valued Multi-Scale Fully Convolutional Network with Stacked-Dilated Convolution for PolSAR Image Classification," In *Remote Sensing*, vol. 15, pp. 3737-3739, 2022.
- [27] Liu, Guangyuan, Yangyang Li, Yanqiao Chen, Ronghua Shang, and Licheng Jiao, "Pol-NAS: A Neural Architecture Search Method With Feature Selection for PolSAR Image Classification," In *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 15, pp.9339-9354, 2022.
- [28] Breyer, Marcel, Alexander Van Craen, and Dirk Pflüger, "A Comparison of SYCL, OpenCL, CUDA, and OpenMP for Massively Parallel Support Vector Machine Classification on Multi-Vendor Hardware," In *International Workshop on OpenCL*, vol.3, pp. 1-12. 2022.
- [29] Jamali, Ali, Masoud Mahdianpari, Fariba Mohammadimanesh, Avik Bhattacharya, and Saeid Homayouni, "PolSAR image classification based on deep convolutional neural networks using wavelet transformation," In *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5, 2022.
- [30] Khandelwal, Monika, Nazir Shabbir, and Saiyed Umer, "Extraction of Sequence-Based Features for Prediction of Methylation Sites in Protein Sequences." In *Artificial Intelligence Technologies for Computational Biology*, vol. 1, pp. 29-46, 2022.
- [31] Sun, Jili, Lingdong Geng, and Yize Wang, "A Hybrid Model Based on Superpixel Entropy Discrimination for PolSAR Image Classification." In *Remote Sensing*, vol. 14, pp. 4116-4129, 2022.
- [32] Ramírez-Rojas, A., P. R. Cárdenas-Moreno, and C. A. Vargas, "Mutual information analysis between NO2 and O3 pollutants measured in Mexico City before and during 2020 Covid-19 pandemic year," In *Journal of Physics: Conference Series*, vol. 2307, pp. 12053-12059. 2022.
- [33] Dong, Wei, Junsheng Wu, Yi Luo, Zongyuan Ge, and Peng Wang, "Node Representation Learning in Graph via Node-to-Neighbourhood Mutual Information Maximization," In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, vol.1, pp. 16620-16629. 2022.
- [34] Yu, Peter, A. Kai Qin, and David A. Clausi, "Unsupervised polarimetric SAR image segmentation and classification using region growing with edge penalty," In *IEEE Transactions on Geoscience and Remote Sensing*. vol. 4, pp. 1302-1317, 2011.
- [35] Köppen, Mario, "The curse of dimensionality," In *5th Online World Conference on Soft Computing in Industrial Applications (WSC5)*, vol. 1, pp. 12-17, 2000.
- [36] Kikukawa, Atsushi, Kiwamu Tanahashi, Yukio Honda, Yoshiyuki Hirayama, and Masaaki Futamoto,