

بررسی عملکرد الگوریتم‌های فراابتکاری جمعیت مبنا به منظور بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان در طبقه‌بندی تصاویر پلاریمتریک راداری

فرهاد صمدزادگان^۱، الهه فردوسی^{۲*}

^۱ دانشیار گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران

samadz@ut.ac.ir

^۲ دانشجوی کارشناسی ارشد فتوگرامتری - گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران

elahe_ferdosi@ut.ac.ir

(تاریخ دریافت خرداد ۱۳۹۲، تاریخ تصویب دی ۱۳۹۲)

چکیده

با توجه به اینکه استفاده از پلاریزاسیون‌های مختلف امواج الکترومغناطیسی در تصویربرداری پلاریمتریک راداری اطلاعاتی غنی از جنبه‌های مختلف عوارض را فراهم می‌کند. امروزه تصاویر پلاریمتری به عنوان ابزار قوی و کارآمد در زمینه‌ی شناسایی عوارض مختلف در مناطق جغرافیایی پیچیده مورد توجه قرار گرفته‌اند. به منظور استخراج اطلاعات، طبقه‌بندی این تصاویر حائز اهمیت می‌باشد. طبقه‌بندی کننده‌ی ماشین‌های بردار پشتیبان به سبب عملکردش بر مبنای ویژگی‌های هندسی و پایداری در فضاهای با ابعاد بالا گزینه‌ی مناسبی در طبقه‌بندی تصاویر پلاریمتری محسوب می‌شود. اما عملکرد این طبقه‌بندی کننده به شدت تحت تاثیر پارامترهای در نظر گرفته شده برای آن می‌باشد. بنابراین به منظور به کارگیری طبقه‌بندی کننده‌ی ماشین‌های بردار پشتیبان با بیشترین کارایی، می‌بایست مقادیر بهینه برای این پارامترها تعیین شوند. روش‌های بهینه‌سازی سنتی متداول به سبب مواجه شدن با پیچیدگی‌های محاسباتی در این فضاهای جستجوی بزرگ اغلب به بهینه‌های محلی همگرا می‌شوند. بنابراین به منظور بدست آوردن مقدار بهینه‌ی سراسری استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری که از جستجوی سراسری همراه با جستجوی محلی بهره می‌گیرند، اجتناب ناپذیر است. در این مقاله توانایی الگوریتم‌های ژنتیک، زنبورها و توده‌ی ذرات به عنوان تکنیک‌های بهینه‌سازی فراابتکاری قدرتمند، در تعیین مقدار بهینه‌ی پارامترهای ماشین‌های بردار پشتیبان ارزیابی شده است. مقایسه نتایج بدست آمده، توانایی بالای الگوریتم توده‌ی ذرات را در زمینه‌ی دقت طبقه‌بندی و سرعت همگرایی نشان می‌دهد.

واژگان کلیدی: ماشین‌های بردار پشتیبان، طبقه‌بندی، تصاویر پلاریمتریک راداری، انتخاب مدل، الگوریتم زنبورها، الگوریتم توده‌ی ذرات، الگوریتم ژنتیک.

* نویسنده رابط

۱- مقدمه

در سال‌های اخیر با پیشرفت تکنولوژی در ساخت و توسعه‌ی سنجنده‌های سنجش از دور، استفاده از سیستم‌های تصویربرداری پلاریمتریک راداری^۱ با قابلیت انتشار و دریافت امواج الکترومغناطیسی در پلاریزاسیون‌های مختلف به صورت گسترده‌ای مورد توجه قرار گرفته است. این قابلیت نه تنها باعث فراهم شدن اطلاعات پراکنشی بیشتر در مورد عوارض موجود در تصویر می‌شود، بلکه موجب تمایز هرچه بهتر عوارض مشابه نیز می‌گردد [۲،۱].

ماشین‌های بردار پشتیبان^۲ به عنوان یک روش یادگیری با توجه به عملکرد مناسب در فضاهای با ابعاد بالا و عدم نیاز به تخمین ویژگی‌های آماری، ابزاری کارآ و موثر برای طبقه‌بندی تصاویر پلاریمتری محسوب می‌شوند. اما از آنجائیکه انتخاب مقدار بهینه برای پارامترهای ماشین‌های بردار پشتیبان و یا به عبارت دیگر انتخاب مدل تاثیر بسزایی بر دقت طبقه‌بندی دارد، بنابراین تعیین مقدار بهینه‌ی پارامترها از اهمیت خاصی برخوردار است [۳].

الگوریتم جستجوی شبکه‌ای^۳، به عنوان روشی متداول در انتخاب پارامترها است که بر مبنای جستجوی گسترده‌ی تمامی مقدارهای ممکن برای پارامترهای ماشین‌های بردار پشتیبان و انتخاب مجموعه‌ای از پارامترها که بیشترین دقت طبقه‌بندی را حاصل می‌کنند، شکل گرفته است [۴]. روش جستجوی شبکه‌ای بسیار زمانبر بوده [۵، ۶] و همواره با محدودیت‌هایی در تراکم شبکه‌ی جستجو مواجه است، این عوامل موجب شده الگوریتم‌های بهینه‌سازی مختلفی برای حل مسائل بهینه‌سازی ارائه و بررسی شوند [۴، ۵، ۷].

از میان الگوریتم‌های بهینه‌سازی ارائه شده، الگوریتم‌های فراابتکاری به سبب جستجوی سراسری^۴ همراه با جستجوی محلی^۵ به طور موفقیت‌آمیزی در انتخاب پارامترها استفاده شده‌اند. الگوریتم‌های فراابتکاری را می‌توان به دو دسته مسیر مبنا و جمعیت مبنا تقسیم

نمود. الگوریتم‌های جمعیت مبنا خود شامل الگوریتم‌های خرد جمعی^۶ (الگوریتم توده‌ی ذرات و زنبورها) و الگوریتم‌های تکاملی^۷ (الگوریتم ژنتیک) می‌باشند [۷].

در این مقاله توانایی الگوریتم‌های ژنتیک، زنبورها و توده‌ی ذرات در بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان به منظور طبقه‌بندی تصاویر پلاریمتری ارزیابی شده است. از طرف دیگر به منظور مقایسه‌ی نتایج بدست آمده، روش جستجوی شبکه‌ای پیاده‌سازی شده است. نتایج بدست آمده از یک سو نشانگر توانایی الگوریتم‌های فراابتکاری از لحاظ دقت طبقه‌بندی و سرعت اجرا می‌باشند و از سوی دیگر عملکرد بالای الگوریتم توده‌ی ذرات را در تعیین مقادیر بهینه پارامترها به اثبات می‌رسانند.

۲- پلاریمتری راداری

پایه و اساس پلاریمتری راداری بر مفهوم پراکنش مبتنی می‌باشد. اطلاعات امواج پراکنش یافته از تارگت-های زمینی کاملاً مرتبط با ساختار هندسی و ویژگی‌های ژئوفیزیکی این تارگت‌ها بوده و به صورت ماتریس پراکنش مطابق با رابطه‌ی (۱) ارائه می‌شوند [۸، ۹].

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (1)$$

اگرچه تصاویر پلاریمتری کامل در مقایسه با سیستم-های متداول تک پلاریزه منبع غنی از اطلاعات را فراهم می‌کنند [۸]، اما استخراج ویژگی‌های تارگت زمینی با توجه به پیچیدگی‌های بهمکنش موج الکترومغناطیسی و مواد تشکیل دهنده‌ی تارگت زمینی یکی از مسائل چالش برانگیز در زمینه‌ی طبقه‌بندی تصاویر پلاریمتری می‌باشد. [۸، ۱، ۲].

۲-۱- استخراج ویژگی‌ها

در سیر طبقه‌بندی داده‌های پلاریمتری استخراج اطلاعات فیزیکی، از امواج پراکنش یافته‌ی بازگشتی توسط ساختارهای سطحی و حجمی گامی مهم به شمار می‌رود [۸]. به منظور استخراج ویژگی‌های تصاویر

^۶ Swarm Intelligence

^۷ Evolutionary

^۱ Polarimetric Radar

^۲ Support Vector Machines

^۳ Grid Search

^۴ Exploration

^۵ Exploitation

بر طبق جدول ۱، تقسیم بندی کلی ارائه شده برای روش‌های تجزیه‌ی تارگت عبارت است از : روش‌های تجزیه تارگت همدوس، بر مبنای تجزیه‌ی ماتریس پراکنش و روش‌های تجزیه تارگت نا همدوس، بر مبنای تجزیه‌ی ماتریس کوواریانس یا همدوسی [۱۳، ۱۲، ۱۰]. از آنجائیکه تکنیک‌های تجزیه‌ی تارگت ماتریس پراکنش حاصل را به مولفه‌های مستقل مرتبط با مکانیزم‌های پراکنش متناظر تقسیم می‌کنند، ویژگی‌های استخراج شده در این حالت دارای مفهوم فیزیکی می‌باشند [۲].

علاوه بر روش‌های تجزیه‌ی تارگت می‌توان برخی از ویژگی‌ها را مستقیماً با استفاده از ماتریس پراکنش استخراج کرد. این ویژگی‌ها تحت عنوان پارامترهای پلاریمتری شناخته شده که برخی از آنها در جدول ۲ ارائه شده‌اند.

جدول ۲- ارائه‌ی پارامترهای پلاریمتری استخراج شده	
پارامترهای پلاریمتری	توصیف ویژگی‌ها
شدت پس پراکنش دریافتی [۱۱، ۸، ۱]	$\sigma_{hh}^o = \langle S_{hh} S_{hh}^* \rangle$ $\sigma_{hh}^o, \sigma_{hv}^o, \sigma_{vv}^o$
المان‌های ماتریس پراکنش [۱۴، ۱۳، ۱۲، ۱]	$\sigma_{hh} = 10 \log S_{hh} ^2$ $\sigma_{hv} = 10 \log S_{hv} ^2$ $\sigma_{hh} = 10 \log S_{vv} ^2$
نسبت‌های بین المان‌های ماتریس پراکنش [۱۱، ۱]	$10 \log \left(\frac{ S_{vv} ^2}{ S_{hh} ^2} \right)$ $10 \log \left(\frac{ S_{hv} ^2}{ S_{hh} ^2} \right)$
اختلاف فاز پلاریزاسیون [۱۱، ۱]	$\varphi_{AB-XY} = \arg \left(\langle S_{AB} S_{XY}^* \rangle \right)$ $\varphi_{hh-vv}, \varphi_{hh-hv}, \varphi_{vv-hv}$
ضریب همبستگی کانال-ها [۱۲، ۱۱، ۱]	$\rho_{AB,XY} = \frac{\langle S_{AB} S_{XY}^* \rangle}{\sqrt{\langle S_{AB} S_{AB}^* \rangle \langle S_{XY} S_{XY}^* \rangle}}$ $\rho_{hh,vv}, \rho_{hv,vv}, \rho_{hh,hv}$
نسبت بین المان‌های ماتریس پراکنش به کل توان [۱۱، ۱]	$R_{hh} = \frac{ S_{hh} ^2}{SPAN}$ Rhh , Rvv , Rhv
توان پراکنش کلی [۹، ۱]	$SPAN = S_{hh} ^2 + S_{vv} ^2 + 2 S_{hv} ^2$
درجه‌ی پلاریزاسیون [۱۲، ۱۱، ۱]	$DoP = \frac{\sqrt{R_1^2 + R_2^2 + R_3^2}}{R_0}$
ارتفاع پدستال [۱]	$\psi = \frac{\min(\lambda_1, \lambda_2, \lambda_3)}{(\lambda_1 + \lambda_2 + \lambda_3)}$

پلاریمتری دو راهکار کلی را می‌توان در نظر گرفت : ۱) به کار بردن روش‌های تجزیه‌ی تارگت ۱) استخراج ویژگی‌ها با استفاده‌ی مستقیم از ماتریس پراکنش [۱۱].
ایده‌ی اصلی روش‌های تجزیه‌ی تارگت، تعریف ساختار هدف زمینی مطابق با ویژگی‌های پراکنش فیزیکی تارگت است [۱۲]. روش‌های تجزیه‌ی تارگت به تفصیل در جدول ۱ بررسی شده‌اند.

جدول ۱- ارائه‌ی روش‌های تجزیه‌ی تارگت		
توصیف ویژگی‌ها	عنوان تکنیک	رده بندی روش‌ها
$ \alpha ^2 = \frac{ S_{hh} + S_{vv} }{\sqrt{2}}$ $ \beta ^2 = \frac{ S_{hh} - S_{vv} }{\sqrt{2}}$ $ \delta ^2 = \sqrt{2} S_{HV}$	Pauli [۱]	تجزیه تارگت همدوس
$k_s = S_d $ $k_h = abs(S_{rr} - S_{ll})$ $k_d = \min(S_{rr} , S_{ll})$	Krogager [۱۰، ۱]	
$T_{11T} = 2A_{0T}$ $T_{22T} = B_{0T} + B_T$ $T_{33T} = B_{0T} - B_T$	Huynen [۸، ۱]	تجزیه تارگت ناهمدوس
$T_{11T} = \frac{(\langle C \rangle - \langle G \rangle)^2 + (\langle H \rangle - \langle D \rangle)^2}{2(\langle B_0 \rangle - \langle F \rangle)}$ $T_{22T} = \frac{(\langle B_0 \rangle + \langle B \rangle - \langle F \rangle)^2 + \langle E \rangle^2}{2(\langle B_0 \rangle - \langle F \rangle)}$ $T_{33T} = \frac{(\langle B_0 \rangle - \langle B \rangle - \langle F \rangle)^2 + \langle E \rangle^2}{2(\langle B_0 \rangle - \langle F \rangle)}$	Holm and Barnes [۱]	
$P_s = f_s(1 + \beta ^2)$ $P_d = f_d(1 + \alpha ^2)$ $P_v = \frac{8}{3} f_v$	Freeman and Durden [۱۰، ۱]	
$P_s^y = f_s(1 + \beta ^2)$ $P_d^y = f_d(1 + \alpha ^2)$ $P_v^y = f_v$	Yamaguchi [۱۳، ۱۰، ۲، ۱]	
$T_{11} = 2A_0$ $T_{22} = B_0 + B$ $T_{33} = B_0 - B$	Cloude [۱]	
$T_{11} = 2A_0$ $T_{22} = B_0 + B$ $T_{33} = B_0 - B$	Holm [۱]	
مقدارهای ویژه آنیستروپی آنیستروپی زوایای $\delta, \alpha, \beta, \omega, \gamma$	Cloude and Pottier [۱۰، ۹، ۸، ۱]	تجزیه-های بردار ویژه مبنا

^ Target Decomposition

۳- ماشین های بردار پشتیبان

با حل مسئله ی مقید (۲)، تابع تصمیم گیری بهینه بر مبنای روش لاگرانژ طبق معادله (۳) محاسبه می شود.

$$f(x) = \sum_{x_i \in SV} y_i \alpha_i K(x_i, x) + b \quad (3)$$

در این رابطه α_i ضرایب لاگرانژ است که در پروسه بهینه سازی محاسبه می شود و داده های آموزشی SV بردارهای پشتیبان هستند. این داده های آموزشی، نزدیک ترین نمونه ها به فرایند بهینه بوده و ضریب لاگرانژ متناظر آنها بزرگتر از صفر است. برای سایر نمونه های آموزشی ضریب لاگرانژ صفر است [۳]. به منظور انتقال داده های غیرخطی به فضایی با ابعاد بالاتر از تابع کرنل استفاده می شود. از پرکاربردترین توابع کرنل می توان به کرنل گوسین و کرنل پلی نومیال [۱۶، ۸] اشاره کرد که به ترتیب در روابط (۴) و (۵) بیان شده اند.

$$K(x_i, x) = \exp\left(-\sigma \|x_i - x\|^2\right) \quad (4)$$

$$K(x_i, x) = (x_i \cdot x + 1)^d \quad (5)$$

در این روابط، σ پارامتر کرنل گوسین و d متغیر کرنل پلی نومیال می باشد [۵، ۳].

در حالت پایه الگوریتم SVMs به منظور طبقه بندی باینری طراحی شده است، این در حالیست که روش های مختلفی برای استفاده از آن در حالت چند کلاسه ارائه شده است [۱۴، ۳]. از میان این روش ها الگوریتم های یک در مقابل یک و یک در مقابل مابقی [۸، ۴، ۳]، با توجه به سادگی و عملکرد مناسبشان و به صورت گسترده تری در حل مسائل چند کلاسه به کار می روند. در حقیقت این الگوریتم ها مسئله ی چند کلاسه را به مسئله ای با چندین طبقه بندی کننده ی باینری تبدیل می کنند [۱۷، ۱۴].

۴- الگوریتم ژنتیک

الگوریتم ژنتیک از نظریه ی انتخاب طبیعی الهام می گیرد [۵] و با دارا بودن قابلیت جستجوی محلی و تصادفی، می تواند در مسائل بهینه سازی پیچیده به صورت کارآمد عمل نماید. ایده ی اصلی این الگوریتم بهبود کیفیت یک جمعیت اولیه از راه حل ها در فرایندی تکراری به منظور حل مسئله ی بهینه سازی می باشد.


ماشین های بردار پشتیبان (SVMs)، از جمله روش های طبقه بندی نظارت شده بر مبنای نظریه یادگیری آماری می باشد [۱۵، ۳]. ایده ی اصلی ماشین های بردار پشتیبان یافتن یک فرایند بهینه به عنوان یک سطح تصمیم گیری برای جدا کردن دو کلاس با بیشترین حاشیه جداسازی می باشد [۱۶]. در صورتیکه نمونه ها به صورت خطی جداپذیر نباشند، با استفاده از یک کرنل غیرخطی به فضایی با ابعاد بالاتر منتقل می شوند و فرایند جداسازی در آن فضای جدید تعریف می شود [۱۷، ۴].

با فرض اینکه x_i بردار ویژگی n بعدی و $y_i \in \{-1, 1\}$ برچسب نمایشگر کلاس ها باشد، هریک از داده های آموزشی را می توان به صورت (x_i, y_i) نمایش داد. پیدا کردن فرایند بهینه ای به منظور جداسازی دو کلاس با بیشترین حاشیه، منجر به حل مسئله ی بهینه سازی مقید مطابق با معادله (۲) می شود.

$$\text{Min} \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \right) \quad (2)$$

$$\text{Subject to: } y_i (wK(x_i) + b) > 1 - \xi_i \quad i = 1, \dots, l$$

در نظر گرفتن قید موجب می شود تا داده ای در حاشیه ی دو کلاس قرار نگیرد. در این رابطه، w بردار وزن (عمود بر فرایند بهینه) و b بردار بایاس (فاصله ی فرایند بهینه تا مبدا) می باشد. پارامتر C ، پارامتر تنظیم است که تعادل میان کمینه شدن خطا و کمینه شدن پیچیدگی های مدل را برقرار می نماید. به منظور در نظر گرفتن تداخل بین داده های آموزشی، از متغیر $\xi_i > 0$ استفاده می شود و $K(\cdot)$ تابع کرنل است که برای انتقال داده ها به فضایی با ابعاد بالاتر استفاده می شود [۱۴، ۸، ۴].



شکل ۱- نمایش فرایند بهینه ی جداکننده ی دو کلاس

نماینده انتخاب می‌شود و باقیمانده‌ی زنبورها به منظور جستجوی مناطق جدید به ساخت راه‌حل تصادفی می‌پردازند. این مراحل تا برآورده شدن شرط توقف تکرار می‌گردند.

۶- الگوریتم توده‌ی ذرات

الگوریتم توده‌ی ذرات الهام گرفته از تعامل و حرکت گروهی موجود میان دسته‌ای از موجودات مانند پرندگان است که منجر به یافتن نواحی مطلوب می‌گردد. این الگوریتم به دلیل پیاده‌سازی آسان و سرعت همگرایی بالا [۴] در حل مسائل بهینه‌سازی بسیار مورد توجه قرار گرفته است.

در الگوریتم توده‌ی ذرات به منظور یافتن راه‌حل‌های بهینه در ابتدا از مجموعه‌ای از ذرات که به صورت تصادفی شکل گرفته‌اند، استفاده می‌شود. هر کدام از ذرات که نمایانگر یک راه‌حل منتخب در فضای جستجو هستند، دارای بردار سرعت و موقعیت اولیه می‌باشند. در طی الگوریتم ارزیابی عملکرد ذرات با اندازه‌گیری تابع هدف تعریف شده صورت می‌پذیرد [۲۰]. برای پیدا کردن بهترین راه‌حل تمامی ذرات می‌بایست در فضای جستجو با توجه به موقعیت ذره‌ای که بهترین عملکرد را دارد جا به جا شوند. برای این منظور سرعت و موقعیت هر ذره با در نظر گرفتن بهترین موقعیتی که تا کنون تجربه کرده و بهترین موقعیت بدست آمده در بین همسایگان ذره مطابق با روابط (۶) و (۷) به هنگام می‌شود.

$$v_i(t+1) = w.v_i(t) + c_1 \cdot r_1(p_best_i - x_i) + c_2 \cdot r_2(g_best_i - x_i) \quad (6)$$

$$x_i(t+1) = x_i(t) + \beta v_i(t+1) \quad (7)$$

در این روابط v_i بیانگر بردار سرعت ذره‌ی i ام، t تعداد تکرارها، w وزن اینرشیا به منظور ایجاد تعادل بین جستجوی محلی و سراسری [۶]، $C1$ و $C2$ ضرایب شتاب، $r1$ و $r2$ اعداد تصادفی در بازه‌ی $[0,1]$ ، p_best_i بهترین موقعیت ذره تا کنون، g_best_i بهترین موقعیت ذره بین همسایگان، x_i بردار سرعت ذره و β ضریب کنترل وزن سرعت می‌باشند. مراحل الگوریتم تا رسیدن به شرط توقف تکرار می‌شوند [۱۵].

اولین گام در الگوریتم ژنتیک تولید یک جمعیت اولیه از راه‌حل‌ها است که در ابتدا به صورت تصادفی ساخته می‌شوند. هر عضو از این مجموعه به صورت رشته‌ای که کروموزم نامیده می‌شود، کدگذاری می‌شود [۱۵،۳]. سپس در مرحله‌ی ارزیابی، کیفیت راه‌حل‌ها با تابع هدف اندازه‌گیری می‌شود. در مرحله‌ی انتخاب، متناسب با میزان کیفیت اندازه‌گیری شده بهترین اعضاء انتخاب می‌شوند. در گام بعدی به منظور ایجاد جمعیت جدید، از عملگرهای ترکیب^۱ و جهش^۲ استفاده می‌شود. این مراحل تکرار می‌شوند تا شرط توقف که می‌تواند بیشترین تعداد تکرار باشد، برقرار شود [۷،۵].

۵- الگوریتم زنبورها

الگوریتم زنبورها با الهام از رفتار جستجوی غذای زنبورهای عسل شکل گرفته است [۱۸] و با توجه به پایداری بالا و عملکرد مناسب به عنوان یک ابزار بهینه‌سازی قدرتمند شناخته شده است. زنبورها در طبیعت برای جستجوی غذا به صورت تصادفی به جستجو در میان سایت‌های گل می‌پردازند. با پیشرفت مراحل جستجو سایت‌های گل با کیفیت بهتر در قیاس با سایت‌هایی با کیفیت پایین‌تر، توسط زنبورهای بیشتری ملاقات می‌شود و سایر زنبورهای باقی مانده به جستجوی تصادفی به منظور کشف مناطق جدید می‌پردازند [۱۸].

اولین مرحله در الگوریتم زنبورها جستجوی تصادفی به منظور کشف راه‌حل‌های بهینه است. برای این منظور هریک از زنبورها به عنوان یک راه‌حل ارائه شده به صورت تصادفی ساخته می‌شوند. در مرحله‌ی ارزیابی، کیفیت راه‌حل‌های ارائه شده توسط تابع هدف ارزیابی می‌شوند و بهترین آنها انتخاب می‌گردند. در مرحله‌ی جستجوی محلی از میان زنبورهای در نظر گرفته شده برای این منظور تعداد بیشتری برای جستجو در همسایگی مناطق مربوط به برترین راه‌حل‌ها نسبت به سایر مناطق انتخابی اختصاص داده می‌شوند. این نوع تخصیص تاثیر بسزایی در عملکرد موفق الگوریتم دارد. بعد از مرحله‌ی جستجو، بهترین راه‌حل بر مبنای تابع هدف، در هر منطقه به عنوان

^۱ Crossover

^۲ Mutation

۷- تعیین مقادیر بهینه پارامترهای ماشین- های بردار پشتیبان

به منظور ارائه‌ی یک طبقه‌بندی کننده‌ی SVMs بالاترین دقت و بیشترین کارایی تعیین مقدار بهینه‌ی پارامترها که عبارتند از : پارامتر تنظیم C و پارامترهای کرنل، از اهمیت ویژه‌ای برخوردار است [۱۲، ۱۷]. تاکنون الگوریتم‌های سنتی و هوشمند بسیاری برای این منظور ارائه شده‌اند. از جمله‌ی آنها می‌توان به روش جستجوی شبکه‌ای [۴] و روش‌های گرادیان مبتنی [۶] اشاره کرد. این روش‌ها به علت زمانبر بودن، داشتن پیچیدگی‌های محاسباتی و نیاز به در نظر گرفتن فرضیاتی در روند حل مسئله اغلب در تعیین مقدار بهینه‌ی پارامترها با شکست مواجه می‌شوند [۲۰]. در سال‌های اخیر استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری به سبب توانایی بالا در کشف راه‌حل بهینه‌ی سراسری بسیار مورد توجه قرار گرفته است.

در ادامه تعیین مقادیر بهینه‌ی پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم‌های فراابتکاری نظیر ژنتیک، زنبورها و توده‌ی ذرات شرح داده شده است. همچنین روش جستجوی شبکه‌ای به عنوان روشی کلاسیک، برای مقایسه نتایج به کار گرفته شده است.

۸- بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان بر مبنای جستجوی شبکه‌ای

همانطور که پیشتر اشاره شد، یکی روش‌های متداول برای تعیین پارامترهای مدل روش جستجوی شبکه‌ای است. در واقع در این روش شبکه‌ای با فواصل معین بر روی محدوده‌ی پارامترهای مسئله در نظر گرفته می‌شود و در طی یک جستجوی گسترده، مجموعه‌ای از جواب‌ها بر روی شبکه‌ی انتخابی محاسبه می‌گردد [۱۷]. بنابراین روش جستجوی شبکه‌ای نه تنها بسیار زمانبر است بلکه دقت این روش نیز کاملاً به تراکم نقاط شبکه‌ی انتخابی بستگی دارد [۴، ۵]. در فضای پیوسته به منظور ارزیابی نقاط بیشتر، می‌بایست شبکه را متراکم‌تر در نظر گرفت. این امر خود موجب افزایش زمان محاسبات می‌شود.

بنابراین برای دستیابی به دقت مناسب و کاهش زمان محاسبات، می‌توان در ابتدا از شبکه‌ای با تراکم پایین‌تر استفاده کرد و پس از مشخص شدن نواحی که بیشترین دقت را دارند، شبکه‌ای با تراکم بالاتر را در آن مناطق در نظر گرفت تا مقدار دقیق پارامترها تعیین شود. در انتها پس از بررسی کامل مقادیر موجود بر روی شبکه‌ی انتخابی پارامترهایی با بیشترین دقت طبقه‌بندی به عنوان پارامترهای مدل انتخاب می‌شوند.

۹- بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم‌های فراابتکاری

به منظور استفاده از الگوریتم‌های فراابتکاری در تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان، اولین گام کدگذاری متغیرهای مسئله به صورت یک رشته‌ی باینری است. طول این رشته متناسب با محدوده‌ی متغیرهاست [۵، ۲۰]. سپس راه‌حل‌های اولیه به شکل تصادفی ساخته می‌شود. هر راه‌حل، یک زوج پارامتر را در قالب یک رشته‌ی باینری مشخص می‌کند. در مرحله‌ی ارزیابی، دقت طبقه‌بندی برای هریک از راه‌حل‌های بدست آمده، بر مبنای تابع هدف اندازه‌گیری می‌گردد. اما از آنجائیکه پارامترهای مجهول SVMs متغیرهای پیوسته می‌باشند، با استفاده از رابطه‌ی (۸) باید فرمت باینری پارامترها را به مقدار حقیقی آنها تبدیل کرد.

$$P = \min_p + \frac{\max_p - \min_p}{2^L - 1} \times d \quad (8)$$

در این رابطه P مقدار حقیقی پارامتر، $\max_p$ و $\min_p$ به ترتیب کران بالا و پایین محدوده‌ی تغییر پارامتر، L و d به ترتیب تعداد و مقدار حقیقی بیت‌های مربوط به پارامتر در طول رشته‌ی باینری می‌باشند [۵]. بنابراین با استفاده از داده‌های آموزشی و مقدار واقعی پارامترهای مشخص شده توسط هر راه‌حل، SVMs آموزش می‌بیند و در مرحله‌ی بعد با به کارگیری داده‌های تست دقت طبقه‌بندی توسط ضریب کاپا اندازه‌گیری می‌شود. در صورت برقرار نشدن شرط توقف، مراحل بهینه‌سازی پارامترها با استفاده از الگوریتم‌های فراابتکاری و ارزیابی دقت طبقه‌بندی تکرار می‌گردند. مراحل اصلی الگوریتم‌های پیشنهادی در شکل ۲ نمایش داده شده است.

مبنای دو معیار ارزیابی، ضریب کاپا و دقت کلی به ترتیب مطابق با روابط (۹) و (۱۰) محاسبه گردد.

$$Kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (9)$$


$$Overall Accuracy = \frac{\sum_{i=1}^r x_{ii}}{N} \times 100 \quad (10)$$

در این روابط، N تعداد کل نمونه‌ها، r تعداد کلاس‌ها، x_{ii} عناصر روی قطر اصلی ماتریس خطا، x_{i+} جمع حاشیه‌ای سطرها و x_{+i} جمع حاشیه‌ای ستون‌ها می‌باشد. در ابتدا روش جستجوی شبکه‌ای برای تعیین پارامترهای SVMs بر مبنای کرنل گوسین و کرنل پلی‌نومیل در - محدوده‌ی $C \in [2^{-5}, \dots, 2^{15}]$ ، $\sigma \in [2^{-5}, \dots, 2^5]$ و $d \in [2^0, \dots, 2^5]$ پیاده‌سازی شده و بر اساس آن زوج پارامترها با بیشترین دقت طبقه‌بندی انتخاب شده‌اند. سپس الگوریتم‌های فراابتکاری به منظور تعیین مقدار بهینه‌ی پارامترها در محدوده‌ی متغیرها به کار گرفته شدند. مقادیر بهینه پارامترها و دقت متناظر با آنها، برای دو حالت کرنل گوسین و پلی‌نومیل در جدول ۳ ارائه شده است.

جدول ۳- مقادیر بهینه پارامترها

روش	پارامتر کرنل گوسین	پارامتر کرنل گوسین	پارامتر کرنل پلی‌نومیل
جستجوی شبکه‌ای	۳۲	۱	۳
الگوریتم ژنتیک	۵۶/۱۳	۲/۴۸	۳/۰۲
الگوریتم زنبورها	۶۰/۷	۱/۷۶	۲/۵۸
الگوریتم توده‌ی ذرات	۶۴/۲۳	۱/۳۴	۲/۷۲

از آنجائیکه الگوریتم جستجوی شبکه‌ای، برای تعیین مقادیر بهینه پارامترها، جستجوی جامع و کاملی بر روی تمامی مقدارهای ممکن پارامترها انجام می‌دهد، دقت بدست آمده از این روش می‌تواند معیار مناسبی برای ارزیابی روش‌های بهینه‌سازی فراابتکاری باشد. همانطور که در جدول ۳ نشان داده شده است، الگوریتم‌های فراابتکاری توانسته‌اند با دقت بالاتری به مقدار بهینه همگرا شوند. نمودار همگرایی تعیین پارامترها بر مبنای الگوریتم‌های فراابتکاری در شکل‌های ۳ و ۴ نمایش داده شده‌است.



شکل ۲- نمودار مراحل بهینه‌سازی پارامترهای SVMs بر مبنای الگوریتم‌های فراابتکاری

۱۰- پیاده‌سازی و ارزیابی نتایج

در مرحله‌ی پیاده‌سازی عملکرد الگوریتم‌های ژنتیک، زنبورها و توده‌ی ذرات در بهینه‌سازی پارامترهای ماشین-های بردار پشتیبان به منظور طبقه‌بندی تصویر پلاریمتری، بررسی و نتایج با روش جستجوی شبکه‌ای مقایسه شده است. به منظور ارزیابی توانایی روش‌های پیشنهادی از کرنل گوسین و پلی‌نومیل بر مبنای الگوریتم یکی در مقابل مابقی استفاده شده است.

روش‌های پیشنهادی بر مبنای الگوریتم‌های فراابتکاری به منظور طبقه‌بندی تصاویر پلاریمتری، بر روی تصویر پلاریمتری کامل اخذ شده توسط سنجنده AIRSAR از منطقه‌ای کشاورزی در Flevoland هلند پیاده‌سازی شده است. این داده به دلیل کلاس‌های پراکنده و مختلف و همچنین شباهت بین مناطق کشاورزی، دارای پیچیدگی‌هایی است که آن را به داده‌ای مناسب برای طبقه‌بندی تبدیل می‌کند. تصویر مورد نظر دارای ابعاد ۷۵۰×۱۰۲۴ پیکسل و ۱۱ کلاس می‌باشد.

در مرحله‌ی ارزیابی نتایج با استفاده از داده‌های تست ماتریس خطا تشکیل داده می‌شود. تا دقت طبقه‌بندی بر

دقت نسبتا مناسبی است، اما به علت پیچیدگی های محاسباتی بیشتر، از سرعت کمتر و هزینه ی پیاده سازی بالاتر برخوردار می باشد.


بدین ترتیب الگوریتم توده ی ذرات با توجه به قابلیت جستجوی تصادفی و محلی بالا و عملکرد موفقیت آمیز گزینه ی مناسبی برای بهینه سازی پارامترهای ماشین های بردار پشتیبان بر مبنای کرنل های گوسین و پلی نومیال می باشد.

جدول ۴- مقایسه ی دقت طبقه بندی بدست آمده با استفاده از الگوریتم های ژنتیک، زنبورها، توده ی ذرات و جستجوی شبکه ای

روش	بر مبنای کرنل گوسین		بر مبنای کرنل پلی نومیال	
	Kappa	OA	Kappa	OA
جستجوی شبکه ای	۰/۸۵	۸۷/۲	۰/۸۳۷	۸۵/۶
الگوریتم ژنتیک	۰/۸۷۳	۸۸/۴	۰/۸۵۴	۸۷
الگوریتم زنبورها	۰/۸۷۹	۸۸/۸	۰/۸۵۵	۸۷/۳
الگوریتم توده ی ذرات	۰/۸۸	۹۰/۳	۰/۸۵۶	۸۷/۹


۱۱- نتیجه گیری

در این مقاله توانایی و کارایی الگوریتم های فراابتکاری ژنتیک، زنبورها و توده ی ذرات در بهینه سازی پارامترهای ماشین های بردار پشتیبان به منظور طبقه بندی تصاویر پلاریمتری مورد بررسی قرار داده شد. به منظور مقایسه ی نتایج بدست آمده از الگوریتم جستجوی شبکه ای که جستجوی جامعی بر روی تمامی مجموعه جواب های ممکن انجام می دهد، استفاده شده است. مقایسه ی نتایج بدست آمده از یک سو عملکرد مناسب الگوریتم های فراابتکاری را از لحاظ دقت و سرعت نسبت به روش کلاسیک جستجوی شبکه ای نشان می دهد و از سوی دیگر توانایی بالای الگوریتم توده ی ذرات را در رسیدن به بهترین دقت طبقه بندی با بهینه سازی مناسب پارامترها بر مبنای کرنل گوسین در زمان کوتاه تر اثبات می کند.



شکل ۳- نمودار همگرایی الگوریتم های ژنتیک، زنبورها و توده ی ذرات در تعیین پارامترهای بهینه SVMs بر مبنای کرنل گوسین

نمودار همگرایی الگوریتم ژنتیک بیانگر همگرایی سریع آن به مقدار بهینه می باشد. در حالی که الگوریتم زنبورها و توده ی ذرات بعد از تکرارهای بیشتری به مقدار بهینه همگرا می شوند. همانطور که در شکل ۳ و جدول ۴ نیز نشان داده شده است، در تعیین مقدار بهینه ی پارامتر- های تنظیم و کرنل گوسین، الگوریتم توده ی ذرات از دقت و سرعت بالاتری نسبت به سایر الگوریتم های بررسی شده برخوردار می باشد.



شکل ۴- نمودار همگرایی الگوریتم های ژنتیک، زنبورها و توده ی ذرات در تعیین پارامترهای بهینه SVMs بر مبنای کرنل پلی نومیال

در تعیین مقدار بهینه ی پارامترهای SVMs بر مبنای کرنل پلی نومیال عملکرد الگوریتم های فراابتکاری تقریبا نزدیک به هم است. نمودار همگرایی الگوریتم ها نشان دهنده ی همگرایی سریع آنها به مقدار بهینه می باشد. اما در هر حال شکل ۴ و جدول ۴ بیانگر عملکرد موفق تر الگوریتم توده ی ذرات در تعیین مقدار بهینه ی پارامترهای تنظیم و کرنل پلی نومیال نسبت به سایر الگوریتم های بررسی شده می باشد. اگرچه الگوریتم زنبورها نیز دارای

مراجع

- [1] Jong-Sen, L. and Pottier, E. (2009). "Polarimetric radar imaging : from basics to applications. " Taylor & Francis Group.
- [2] Han Y. and Shao, Y. (2010). "Full Polarimetric SAR Classification Based on Yamaguchi Decomposition Model and Scattering Parameters" . IEEE.
- [3] Lorena, A. C. and de Carvalho, A. C.P.L.F. (2008). "Evolutionary tuning of SVM parameter values in multiclass problem" *Neurocomputing*, pp.3326-3334.
- [4] Hric, M., Chmulik, M. and Jarina, R. (2011). " Model Parameters Selection for SVM Classification using Particle Swarm Optimization ", *IEEE Radioelektronika*.
- [5] Huang C. L. and Wang, C. J. (2006). " A GA-based feature selection and parameters optimization for support vector machines ", *Expert system with application*, vol. 31, pp. 231-240.
- [6] Jin, G., Jin_Ye, P. and Zhan, Li. (2010). " Application of Improved PSO-SVM Approach in Image Classification ", *IEEE, Photonics and Optoelectronic (SOPO), 2010 Symposium*,.
- [7] Yang, Xin-She., 2010. *Engineering Optimization: An Introduction with Metaheuristic Applications*, Published by John Wiley & Sons.
- [8] Yang, W., Jiaguo, L. and Changyao, Z. (2007). " Algorithm of Target Classification Based on Target Decomposition and Support Vector Machine ", *IEEE*.
- [9] Wentao, A., Chunhua, X., Xinzhe, Y., Yi C. and Jian, Y. (2011). " Four-Component Decomposition of Polarimetric SAR Images With Deorientation ", *IEEE Geoscience and Remote Sensing Letters*.
- [10] Turkar V. and Rao, Y.S. (2011). " Applying Coherent and Incoherent Target Decomposition Techniques to Polarimetric SAR Data ", *International Conference on Technology Systems and Management*, published by International Journal of Computer Applications.
- [11] Molinier, M., Laaksonen, J., Rauste, Y. and Hsime, T. (2007). " Detecting Changes in Polarimetric SAR Data with Content-Based Image Retrieval ".
- [12] Colin-Koeniguer E. and Trouvé, N. (2010). " A review about alternatives to classical Polarimetric SAR parameters ", *EUSAR 2010 - 8th European Conference on Synthetic Aperture Radar*,.
- [13] Ince, T., Kiranyaz S. and Gabbouj, M., (2010). " Classification of Polarimetric SAR Images Using Evolutionary RBF Networks ", *IEEE International Conference on Pattern Recognition*.
- [14] Mountrakis, G., Jungho, Im. and Ogole, C. (2010). " Support vector machines in remote sensing: A review ", *ISPRS Journal of Photogrammetry and Remote Sensing*.
- [15] Kaya, G.T., Ersoy, O.K. and Kamasak, M.E. (2011). " Support Vector Selection and Adaptation for Remote Sensing Classification ", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49.
- [16] Pham D. and Muhamad, Z. (2007). " Using the bees algorithm to optimise a support vector machine for wood defect classification ", *Innovative Production Machines and Systems Virtual Conference*.
- [17] Zhang X. and Guo, Y. (2008). " Optimization of SVM Parameters Based on PSO Algorithm", *IEEE, Fifth International Conference on Natural Computation*.
- [18] Wang J. and Li, T. (2010). " A real time IDSs based on artificial Bee Colony-support vector machine algorithm ", *IEEE. Third International Workshop on Advanced Computational Intelligence*.
- [19] Babaoglu, Findik, O. and Alker, E. (2010). "A comparison of feature selection models utilizing binary particle swarm optimization and genetic algorithm in determining coronary artery disease using support vector machine", *Expert Systems with Applications*, vol. 37, pp. 3177-3183, 10.
- [20] de Souza, B., de Carvalho, A., Calvo, R. and Ishii, R. (2006). " Multiclass SVM model selection using particle swarm optimization", *IEEE, the Sixth International Conference on Hybrid Intelligent Systems (HIS'06)*.

