

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

فرهاد صمدزادگان<sup>۱</sup>، الهه فردوسی<sup>۲\*</sup>

<sup>۱</sup> دانشیار گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران

samadz@ut.ac.ir

<sup>۲</sup> 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 کارآیی، 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 فرالبتکاری 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 فرالبتکاری 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

ماشین‌های بردار پشتیبان<sup>۲</sup> 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<sup>۳</sup>، به عنوان روشی متداول در انتخاب پارامترها است که بر مبنای جستجوی گستردۀ‌ی 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 زمانبُر 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 [۷،۴،۵].

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

<sup>۱</sup> Polarimetric Radar

<sup>۲</sup> Support Vector Machines

<sup>۳</sup> Grid Search

<sup>۴</sup> Exploration

<sup>۵</sup> Exploitation

نمود. الگوریتم‌های جمعیت مبنا خود شامل الگوریتم‌های خرد جمعی<sup>۶</sup> (الگوریتم توده‌ی ذرات و زنبورها) و الگوریتم‌های تکاملی<sup>۷</sup> (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 شبکه ای پیاده‌سازی شده است. نتایج بدست آمده از یک سو نشانگر توانایی الگوریتم‌های فرالبتکاری 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 پرآکنش مبتنی می‌باشد. اطلاعات امواج پرآکنش یافته از تارگت‌های زمینی کاملاً مرتبط با ساختار هندسی و ویژگی‌های ژئوفیزیکی این تارگت‌ها بوده و به صورت ماتریس پرآکنش 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 سیستم‌های متداول تک پلاریزه منبع غنی از اطلاعات را فراهم می‌کنند [۸]، اما استخراج ویژگی‌های تارگت زمینی با توجه به پیچیدگی‌های برهمنکش موج الکترومغناطیسی و مواد تشکیل دهنده‌ی تارگت زمینی یکی از مسائل چالش برانگیز در زمینه‌ی طبقه‌بندی تصاویر پلاریمتری می‌باشد. [۸،۹،۱۰].

### ۲-۱- استخراج ویژگی‌ها

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

<sup>۶</sup> Swarm Intelligence

<sup>۷</sup> Evolutionary

بر طبق جدول ۱، تقسیم بندی کلی ارائه شده برای روش‌های تجزیه‌ی تارگت عبارت است از : روش‌های تجزیه تارگت همدوس، برمنای تجزیه‌ی ماتریس پراکنش و روش‌های تجزیه تارگت نا همدوس، برمنای تجزیه‌ی ماتریس کووریانس یا همدوسی [۱۰، ۱۲، ۱۳]. از آنجاییکه 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

تصویف 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 ماتریش پراکنش به کل تون [۱۱، ۱]	$R_{hh} = \frac{ S_{hh} ^2}{SPAN}$ Rhh , Rvv , Rhv
تون 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	ردی بندی روش‌ها
	Pauli [۱]	$ \alpha ^2 = \frac{ S_{hh} + S_{vv} }{\sqrt{2}}$ $ \beta ^2 = \frac{ S_{hh} - S_{vv} }{\sqrt{2}},$ $ \delta ^2 = \sqrt{2} S_{HV}$
تجزیه تارگت همدوس	Krogager [۱۰، ۱]	$k_S =  S_{rl} $ $k_h = abs( S_{rr}  -  S_{ll} )$ $k_d = \min( S_{rr} ,  S_{ll} )$
	Huynen [۸، ۱]	$T_{11T} = 2A_{0T}$ $T_{22T} = B_{0T} + B_T$ $T_{33T} = B_{0T} - B_T$
	Holm and Barnes [۱]	$T_{11T} = \frac{(\langle C \rangle - \langle G \rangle)^2 + (\langle H \rangle - \langle D \rangle)^2}{2(\langle B_0 \rangle - \langle F \rangle)}$ $T_{22T} = \frac{(\langle B_0 \rangle + \langle B \rangle - \langle F \rangle)^2 + \langle E \rangle^2}{2(\langle B_0 \rangle - \langle F \rangle)}$ $T_{33T} = \frac{(\langle B_0 \rangle - \langle B \rangle - \langle F \rangle)^2 + \langle E \rangle^2}{2(\langle B_0 \rangle - \langle F \rangle)}$
تجزیه های مدل مبنا ناهمدوس	Freeman and Durden [۱۰، ۱]	$P_S = f_S(1 +  \beta ^2)$ $P_d = f_d(1 +  \alpha ^2)$ $P_v = \frac{8}{3} f_v$
تجزیه تارگت مبنا	Yamaguchi [۱۳، ۱۰، ۲، ۱]	$P_S^y = f_S(1 +  \beta ^2)$ $P_d^y = f_d(1 +  \alpha ^2)$ $P_v^y = f_v$
	Cloude [۱]	$T_{11} = 2A_0$ $T_{22} = B_0 + B$ $T_{33} = B_0 - B$
تجزیه های بردار ویژه مبنا	Holm [۱]	$T_{11} = 2A_0$ $T_{22} = B_0 + B$ $T_{33} = B_0 - B$
	Cloude and Pottier [۱۰، ۹، ۸، ۱]	مقدارهای ویژه آنتروپی آئیستروپی زوایای $\delta, \alpha, \beta, \omega, \gamma$

### ۳- ماشین‌های بردار پشتیبان

با حل مسئله‌ی مقید (۲)، تابع تصمیم‌گیری بهینه بر مبنای روش لاگرانژ طبق معادله (۳) محاسبه می‌شود.

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

در این رابطه  $\alpha_i$  ضرایب لاگرانژ است که در پروسه بهینه‌سازی محاسبه می‌شود و داده‌های آموزشی SV بردارهای پشتیبان هستند. این داده‌های آموزشی، نزدیک‌ترین نمونه‌ها به فراصفحه بوده و ضریب لاگرانژ متناظر آنها بزرگتر از صفر است. برای سایر نمونه‌های آموزشی ضریب لاگرانژ صفر است [۳]. به منظور انتقال داده‌های غیرخطی به فضایی با ابعاد بالاتر از تابع کرنل استفاده می‌شود. از پرکاربردترین توابع کرنل می‌توان به کرنل گوسین و کرنل پلی‌نومیال [۱۶,۸] اشاره کرد که به ترتیب در روابط (۴) و (۵) بیان شده‌اند.

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

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

در این روابط،  $\sigma$  پارامتر کرنل گوسین و  $d$  متغیر کرنل پلی‌نومیال می‌باشد [۵,۳].

در حالت پایه الگوریتم SVMs به منظور طبقه‌بندی باینری طراحی شده است، این در حالیست که روش‌های مختلفی برای استفاده از آن در حالت چند کلاسه ارائه شده است [۱۴,۳]. از میان این روش‌ها الگوریتم‌های یک در مقابل یک و یک در مقابل مابقی [۸,۴,۳]، با توجه به سادگی و عملکرد مناسبشان و به صورت گسترده‌تری در حل مسائل چند کلاسه به کار می‌روند. در حقیقت این الگوریتم‌ها مسئله‌ی چند کلاسه را به مسئله‌ای با چندین طبقه‌بندی کننده‌ی باینری تبدیل می‌کنند [۱۷,۱۴].

### ۴- الگوریتم ژنتیک

الگوریتم ژنتیک از نظریه‌ی انتخاب طبیعی الهام می‌گیرد [۵] و با دارا بودن قابلیت جستجوی محلی و تصادفی، می‌تواند در مسائل بهینه‌سازی پیچیده به صورت کارآ عمل نماید. ایده‌ی اصلی این الگوریتم بهبود کیفیت یک جمعیت اولیه از راه حل‌ها در فرآیندی تکراری به منظور حل مسئله‌ی بهینه سازی می‌باشد.

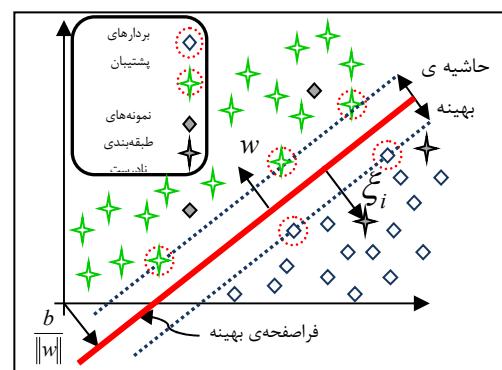
ماشین‌های بردار پشتیبان (SVMs)، از جمله روش‌های طبقه‌بندی نظارت شده بر مبنای نظریه یادگیری آماری می‌باشد [۱۵,۳]. ایده‌ی اصلی ماشین‌های بردار پشتیبان یافتن یک فراصفحه‌ی بهینه به عنوان یک سطح تصمیم‌گیری برای جدا کردن دو کلاس با بیشترین حاشیه جداسازی می‌باشد [۱۶]. در صورتیکه نمونه‌ها به صورت خطی جداپذیر نباشند، با استفاده از یک کرنل غیرخطی به فضایی با ابعاد بالاتر منتقل می‌شوند و فراصفحه‌ی جداکننده در آن فضای جدید تعریف می‌شود [۱۷,۴]

با فرض اینکه  $x_i$  بردار ویژگی  $n$  بعدی و  $y_i \in \{-1, 1\}$  برچسب نمایشگر کلاس‌ها باشد، هریک از داده‌های آموزشی را می‌توان به صورت  $(x_i, y_i)$  نمایش داد. پیدا کردن فراصفحه‌ای به منظور جداسازی دو کلاس با بیشترین حاشیه، منجر به حل مسئله‌ی بهینه‌سازی مقید مطابق با معادله (۲) می‌شود.

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

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

در نظر گرفتن قید موجب می‌شود تا داده‌ای در حاشیه‌ی دو کلاس قرار نگیرد. در این رابطه،  $w$  بردار وزن (عمود بر فراصفحه‌ی بهینه) و  $b$  بردار بایاس (فاصله‌ی فراصفحه تا مبدأ) می‌باشد. پارامتر  $C$ ، پارامتر تنظیم است که تعادل میان کمینه شدن خطأ و کمینه شدن پیچیدگی‌های مدل را برقرار می‌نماید. به منظور در نظر گرفتن تداخل بین داده‌های آموزشی، از متغیر  $\xi_i$  استفاده می‌شود و  $K(\cdot)$  تابع کرنل است که برای انتقال داده‌ها به فضایی با ابعاد بالاتر استفاده می‌شود [۱۴,۸,۴].



شکل ۱- نمایش فراصفحه‌ی بهینه‌ی جداکننده‌ی دو کلاس

نماینده انتخاب می‌شود و باقیماندهی زبورها به منظور جستجوی مناطق جدید به ساخت راه حل 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 راه حل‌های بهینه در ابتدا از مجموعه‌ای از ذرات که به صورت تصادفی شکل گرفته‌اند، استفاده می‌شود. هر کدام از ذرات که نمایشگر یک راه حل منتخب در فضای جستجو هستند، دارای بردار سرعت و موقعیت اولیه می‌باشند. در طی الگوریتم ارزیابی عملکرد ذرات با اندازه‌گیری تابع هدف تعريف شده صورت می‌پذیرد [۲۰]. برای پیدا کردن بهترین راه حل تمامی ذرات می‌باشند 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.

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1(p\_best_i - x_i) + c_2 \cdot r_2(g\_best_i - x_i) \quad (6)$$

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

در این روابط  $v_i$  بیانگر بردار سرعت ذره‌ی  $i$  است،  $t$  تعداد تکرارها،  $w$  وزن اینرشیا به منظور ایجاد تعادل بین جستجوی محلی و سراسری [۶]،  $C1$  و  $C2$  ضرایب  $p\_best_i$ ،  $r1$  و  $r2$  اعداد تصادفی در بازه‌ی  $[0,1]$ ،  $x_i$  ذره بین همسایگان،  $x_i$  بردار سرعت ذره و  $\beta$  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 راه حل‌ها است که در ابتدا به صورت تصادفی ساخته می‌شوند. هر عضو از این مجموعه به صورت رشتهدی که کروموزم نامیده می‌شود، کدگذاری می‌شود [۱۵، ۳]. سپس در مرحله‌ی ارزیابی، کیفیت راه حل‌ها 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 عملکردهای ترکیب<sup>۱</sup> و جهش<sup>۲</sup> استفاده می‌شود. این مراحل تکرار می‌شوند تا شرط توقف که می‌تواند بیشترین تعداد تکرار باشد، برقرار شود [۷، ۵].

## ۵- الگوریتم زبورها

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

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

<sup>۱</sup> Crossover

<sup>۲</sup> Mutation

بنابراین برای دستیابی به دقت مناسب و کاهش زمان محاسبات، می توان در ابتدا از شبکه‌ای با تراکم پایین تر 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 فرالبتکاری

به منظور استفاده از الگوریتم‌های فرالبتکاری 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 [۲۰، ۵]. سپس راه حل‌های اولیه به شکل تصادفی ساخته می‌شود. هر راه حل، یک زوج پارامتر را در قالب یک رشته‌ی باینری مشخص می‌کند. در مرحله‌ی ارزیابی، دقت طبقه‌بندی برای هریک از راه حل‌های بدست آمده، بر مبنای تابع هدف اندازه‌گیری می‌گردد. اما از آنچه‌ایکه پارامترهای مجھول 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 راه حل، آموزش می‌بیند و در مرحله‌ی بعد با به کار گیری داده‌های تست دقت طبقه‌بندی توسط ضریب کاپا اندازه‌گیری می‌شود. در صورت برقرار نشدن شرط توقف، مراحل بهینه‌سازی پارامترها با استفاده از الگوریتم‌های فرالبتکاری و ارزیابی دقت طبقه‌بندی تکرار می‌گرددند. مراحل اصلی الگوریتم‌های پیشنهادی در شکل ۲ نمایش داده شده است.

## ۷- تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان

به منظور ارائه یک طبقه‌بندی کننده‌ی SVMs با 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 مبنا [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 فرالبتکاری به سبب توانایی بالا در کشف راه حل بهینه‌ی سراسری بسیار مورد توجه قرار گرفته است.

در ادامه تعیین مقادیر بهینه‌ی پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم‌های فرالبتکاری نظریه 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 گستردۀ، مجموعه‌ای از جواب‌ها بر روی شبکه‌ای انتخابی محاسبه می‌گردد [۱۷]. بنابراین روش جستجوی شبکه‌ای نه تنها بسیار زمانی 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.

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

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

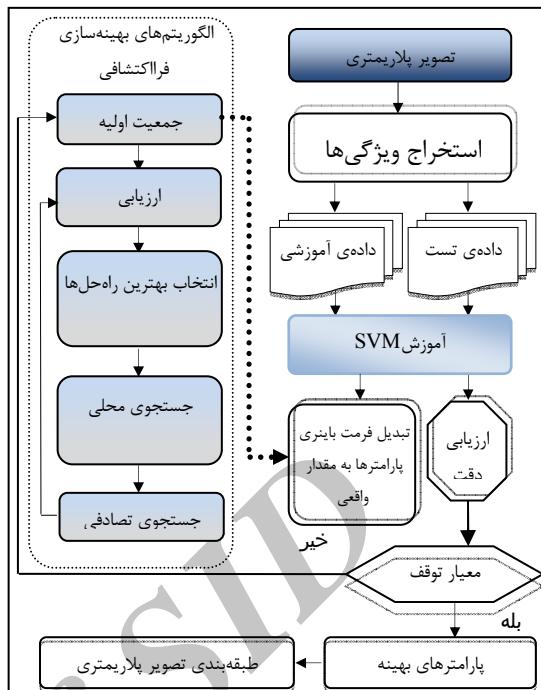
$$Overall\ Accuracy = \frac{\sum_{i=1}^r x_{ii}}{N} \times 100 \quad (10)$$

در این روابط،  $N$  تعداد کل نمونه‌ها،  $r$  تعداد کلاس‌ها،  $x_{ii}$  عناصر روی قطر اصلی ماتریس خطای  $x_{i+}$  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 پلی‌نومیال در محدوده‌ی  $[2^{-5}, 2^{15}]$  و  $C \in [2^{-5}, 2^5]$  پیاده‌سازی شده و بر اساس آن زوج پارامترها با بیشترین دقت طبقه‌بندی انتخاب شده‌اند. سپس الگوریتم‌های فرابتکاری 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 پلی‌نومیال در جدول ۳ ارائه شده است.

جدول ۳- مقادیر بهینه پارامترها

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

از آنجاییکه 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 فرابتکاری باشد. همانطور که در جدول ۳ نشان داده شده است، الگوریتم‌های فرابتکاری توانسته‌اند با دقت بالاتری به مقدار بهینه همگرا شوند. نمودار همگرایی تعیین پارامترها بر مبنای الگوریتم‌های فرابتکاری در شکل‌های ۳ و ۴ نمایش داده شده است.



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

## ۱۰- پیاده‌سازی و ارزیابی نتایج

در مرحله‌ی پیاده‌سازی عملکرد الگوریتم‌های ژنتیک، زنبورها و توده‌ی ذرات در بهینه‌سازی پارامترهای ماشین‌های 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 پلی‌نومیال بر مبنای الگوریتم یکی در مقابل مابقی استفاده شده است.

روش‌های پیشنهادی بر مبنای الگوریتم‌های فرابتکاری به منظور طبقه‌بندی تصاویر پلاریمتری، بر روی تصویر پلاریمتری کامل اخذ شده توسط سنجنده Flevoland AIRSAR از منطقه‌ای کشاورزی در 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  $1024 \times 750$  پیکسل و ۱۱ کلاس می‌باشد.

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

دقت نسبتاً مناسبی است، اما به علت پیچیدگی های محاسباتی بیشتر، از سرعت کمتر و هزینه‌ی پیاده‌سازی بالاتر برخوردار می‌باشد.

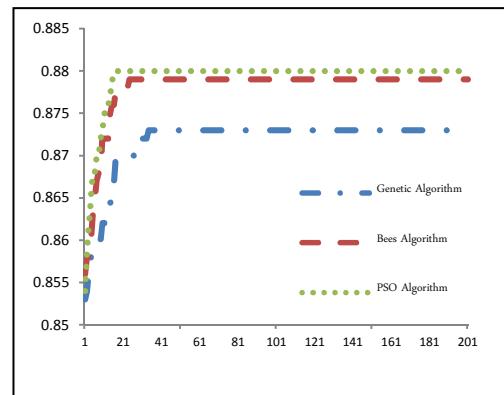
بدین ترتیب الگوریتم توده‌ی ذرات با توجه به قابلیت جستجوی تصادفی و محلی بالا و عملکرد موفقیت‌آمیز گزینه‌ی مناسبی برای بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان بر مبنای کرنل‌های گوسین و پلی‌نومیال می‌باشد.

جدول ۴- مقایسه‌ی دقت طبقه‌بندی بدست آمده با استفاده از الگوریتم‌های ژنتیک، زنبورها، توده‌ی ذرات و جستجوی شبکه‌ای

روش	بر مبنای کرنل پلی		بر مبنای کرنل گوسین	
	Kappa	OA	Kappa	OA
جستجوی شبکه‌ای	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 توده‌ی ذرات	۰/۸۸	۹۰/۳	۰/۸۵۶	۸۷/۹

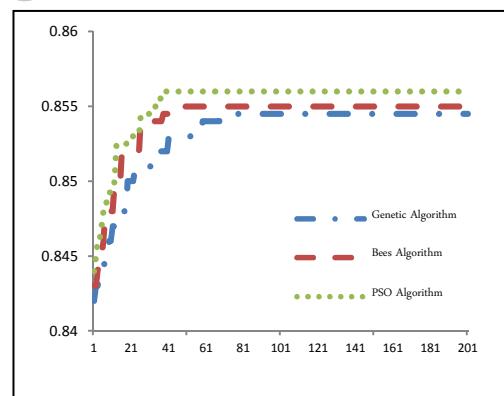
## ۱۱- نتیجه‌گیری

در این مقاله توانایی و کارایی الگوریتم‌های فرالبتکاری ژنتیک، زنبورها و توده‌ی ذرات در بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان به منظور طبقه‌بندی تصاویر پلاریمتری مورد بررسی قرار داده شد. به منظور مقایسه‌ی نتایج بدست آمده از الگوریتم جستجوی شبکه‌ای که جستجوی جامعی بر روی تمامی مجموعه جواب‌های ممکن انجام می‌دهد، استفاده شده است. مقایسه‌ی نتایج بدست آمده از یک سو عملکرد مناسب الگوریتم‌های فرالبتکاری را از لحاظ دقت و سرعت نسبت به روش کلاسیک جستجوی شبکه‌ای نشان می‌دهد و از سوی دیگر توانایی بالای الگوریتم توده‌ی ذرات را در رسیدن به بهترین دقت طبقه‌بندی با بهینه‌سازی مناسب پارامترها بر مبنای کرنل گوسین در زمان کوتاهتر اثبات می‌کند.



شکل ۳- نمودار همگرایی الگوریتم‌های ژنتیک، زنبورها و توده‌ی ذرات در تعیین پارامترهای بهینه SVMs بر مبنای کرنل گوسین

نمودار همگرایی الگوریتم ژنتیک بیانگر همگرایی سریع آن به مقدار بهینه می‌باشد. در حالی که الگوریتم زنبورها و توده‌ی ذرات بعد از تکرارهای بیشتری به مقدار بهینه همگرا می‌شوند. همانطور که در شکل ۳ و جدول ۴ نیز نشان داده شده است، در تعیین مقدار بهینه‌ی پارامترهای تنظیم و کرنل گوسین، الگوریتم توده‌ی ذرات از دقت و سرعت بالاتری نسبت به سایر الگوریتم‌های بررسی شده برخوردار می‌باشد.



شکل ۴- نمودار همگرایی الگوریتم‌های ژنتیک، زنبورها و توده‌ی ذرات در تعیین پارامترهای بهینه SVMs بر مبنای کرنل پلی‌نومیال

در تعیین مقدار بهینه‌ی پارامترهای SVMs بر مبنای کرنل پلی‌نومیال عملکرد الگوریتم‌های فرالبتکاری تقریباً نزدیک به هم است. نمودار همگرایی الگوریتم‌ها نشان دهنده‌ی همگرایی سریع آنها به مقدار بهینه می‌باشد. اما در هر حال شکل ۴ و جدول ۴ بیانگر عملکرد موفق‌تر الگوریتم توده‌ی ذرات در تعیین مقدار بهینه‌ی پارامترهای تنظیم و کرنل پلی‌نومیال نسبت به سایر الگوریتم‌های بررسی شده می‌باشد. 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 Hsame, 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).