

انتخاب زیر مجموعه بهینه ماهواره‌ها با استفاده از مدل ترکیبی SVMPSO به منظور افزایش دقت مکان‌یابی GPS

محمد حسین رفان^۱، عادل دمشقی^۲، مهرنوش کمرزین^۳

۱- استادیار، دانشکده مهندسی برق و کامپیوتر- دانشگاه تربیت دبیر شهید رجایی- تهران- ایران

refan@srutu.edu

۲- کارشناس ارشد، دانشکده مهندسی برق و کامپیوتر- دانشگاه تربیت دبیر شهید رجایی - تهران- ایران

Adel_damesghi@yahoo.com

۳- دانشجوی کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر- دانشگاه شهید بهشتی - تهران- ایران

Mehrnoosh_kamarzarrin@yahoo.com

چکیده: هندسه ماهواره‌ها، نشان‌دهنده مکان‌های هندسی ماهواره‌های GPS است، عاملی که ارتباط هندسی صورت فلکی ماهواره‌های GPS را با همدیگر نشان می‌دهد، GDOP است. همه گیرنده‌ها از الگوریتم‌هایی برای انتخاب ماهواره‌ها استفاده می‌کنند، در این مقاله، هدف استفاده از راهکار دسته‌بندی و تخمین عامل GDOP برای انتخاب زیر مجموعه بهینه ماهواره‌ها است. برای این منظور از مدل ترکیبی SVMPSO استفاده شده است. این مدل بر خلاف روش ماتریس معکوس که به علت تاخیرهای محاسباتی اعلام موقعیت بلادرنگ را دچار نقصان می‌کند، با دقت، سرعت و قابلیت اطمینان بالا عامل GDOP را محاسبه می‌کند. مدل SVM یکی از مدل‌های قوی برای دسته‌بندی و تخمین است، نقش PSO بهینه‌سازی شاخص‌های اساسی SVM است. این روش عملکرد SVM را در دقت و سرعت بهبود می‌دهد. مدل SVMPSO برای دسته‌بندی ماهواره‌های دیده شده با گیرنده ارزان قیمت GPS پیاده‌سازی شد. ۴ نقشه متفاوت برای محاسبه عامل GDOP وجود دارد. شبیه‌سازی هر ۴ نقشه در این مقاله منعکس و با یکدیگر مقایسه شد. پیاده‌سازی مدل و نتایج شبیه‌سازی خطای تخمین مدل SVMPSO را کمتر از ۰/۱۶ و دقت دسته‌بندی آن را بیش از ۹۹ درصد نشان داد. روش ارائه شده با روش‌های GA، NN و SVM که به تازگی برای محاسبه GDOP استفاده شده‌اند، مقایسه شد.

واژه‌های کلیدی: بهینه‌سازی گروهی ذرات، سامانه مکان‌یاب جهانی، ماشین بردار پشتیبان، GDOP.

۱- مقدمه

دهه ۱۹۷۰ گسترش پیدا کرد [۱]. سامانه GPS شامل بیش از ۲۴ ماهواره است، با استفاده از حداقل ۴ ماهواره مکان کاربر در ۳ بعد مشخص می‌شود [۲]. در دقت مکان‌یابی GPS ۲ عامل مؤثر است؛ ۱- خطای مشاهده شده در هر سیگنال دریافتی و ۲- شکل هندسی تشکیل شده از ماهواره‌های قابل مشاهده. عامل GDOP^۱ یک عامل هندسی از پیش تعیین شده است که اثر هندسه را در توصیف رابطه خطای اندازه‌گیری با خطا تعیین موقعیت نشان می‌دهد. در دسترس بودن ماهواره‌های GPS و پیکربندی آن‌ها نیز نقش مهمی در کنار عوامل دیگر بازی می‌کند [۳]. برخی از

سامانه مکان‌یاب جهانی یک نوع سامانه مسیریابی بر اساس ماهواره‌هاست که توسط سازمان دفاعی آمریکا در

^۱ تاریخ ارسال مقاله: ۱۳۹۲/۱۰/۶

تاریخ پذیرش مقاله: ۱۳۹۴/۱۰/۰۷

نام نویسنده‌ی مسئول: محمد حسین رفان

نشانی نویسنده‌ی مسئول: ایران - تهران - لویزان - دانشگاه تربیت دبیر شهید رجایی - دانشکده‌ی مهندسی برق و کامپیوتر

گیرنده‌ها محدودیت‌هایی در تعداد ماهواره‌های قابل مشاهده دارند، بنابراین، نیاز است زیر مجموعه‌ای از ماهواره‌ها انتخاب شود. این زیر مجموعه باید بهترین یا قابل قبول‌ترین فرم هندسی را داشته باشند. بهینه‌ترین زیر مجموعه ماهواره‌ها با حداقل رساندن عامل GDOP انتخاب می‌شود. گیرنده‌های GPS به علت تعداد محدود کانال‌هایشان قادر به پردازش داده‌های همه ماهواره‌های در دسترس نیستند، بنابراین، در این موارد انتخاب زیرمجموعه‌ای از ماهواره‌ها که بهترین یا مناسب‌ترین راه حل را عرضه می‌کنند، ضروری است [۱]. روش‌های موجود برای محاسبه GDOP بیشتر شامل روش‌های ماتریس معکوس، الگوریتم شکل‌دهی مسدود و مقدار حداکثر چهار وجهی است. درست‌ترین روش برای محاسبه GDOP، استفاده از ماتریس معکوس برای کلیه ترکیب‌ها و انتخاب کوچک‌ترین آن‌هاست، اما معکوس کردن ماتریس، به ویژه در زمانی که تعداد ماهواره‌ها زیاد است، بار محاسباتی زیادی برای پردازشگر ناپور به همراه خواهد داشت [۴]. از آنجا که GDOP یک تفسیر ساده را از دقت موقعیت توسط یک واحد از خطای اندازه‌گیری فراهم می‌کند، مطلوب است در صورت فلکی ماهواره‌ای ترکیبی از ماهواره را انتخاب کنید که کوچک‌ترین GDOP ممکن را داشته باشد. روش‌های گوناگونی بر اساس GDOP برای افزایش دقت مکان‌یابی GPS مطرح شده‌اند. به جای محاسبه مستقیم روابط GDOP و جلوگیری از زمان پردازش ماتریس معکوس به‌تازگی از روش‌های شبکه عصبی، الگوریتم ژنتیک و SVM^۲ استفاده شده است [۷-۵]. استفاده از مدل ماشین‌بردار پشتیبان در سال‌های اخیر برای دسته‌بندی و تخمین گسترش یافته است، اما کاربردهای این مدل محدود شده است؛ زیرا کیفیت آن به تعیین شاخص‌های SVM و شاخص‌های کرنل SVM وابستگی زیادی دارد. نیاز است یک روش خودکار، معتبر و با سرعت نسبی زیاد برای تعیین شاخص‌ها انتخاب شود. در این مقاله، از روش PSO^۳ برای تعیین شاخص‌های SVM استفاده شده است. الگوریتم PSO روش جستجوی مبتنی بر جمعیت است که بستگی به اشتراک‌گذاری اطلاعات میان اعضای جمعیت خود دارد، تا فرآیندهای جستجوی خود را با استفاده از ترکیبی از قوانین

قطع و احتمالی ارتقاء دهد. با این حال، PSO اپراتورهای ژنتیکی مانند آمیزش و جهش را ندارد. در مقایسه با GA^۴ نحوه به اشتراک‌گذاری اطلاعات در PSO متفاوت است. همچنین، زمان محاسباتی PSO و تعداد شاخص‌های مورد استفاده در این مدل نسبت به GA کمتر است. ساختار این مقاله به این شکل است؛ در بخش دوم مروری روی کارهای انجام شده درباره دسته‌بندی ماهواره‌ها انجام شده است. بخش سوم مقاله نحوه محاسبه GDOP را بیان می‌کند. بخش چهارم مقاله روش SVMPSO است. بخش پنجم شبیه‌سازی و بررسی نتایج است. مقاله با نتیجه‌گیری در بخش ششم پایان می‌یابد.

۲- مروری بر کارهای گذشته

این بخش به طور مختصر کارهای انجام شده در باره دسته‌بندی و تخمین عامل GDOP را بیان می‌کند. از شبکه عصبی مصنوعی، Simon و همکارانش برای تخمین GDOP استفاده کردند [۸]. یک سری از فعالیت‌های پژوهشی روی انواع شبکه‌های عصبی را Jwo برای این منظور انجام داد [۴]. مبنای شبکه عصبی حداقل‌سازی ریسک ساختاری است، این امر بیشتر موجب کاهش تعمیم‌پذیری خواهد شد. همچنین، این مدل بیشتر موجب افزایش زمان آموزش و تعیین شاخص‌های ساختار شبکه خواهد شد. روش دیگر برای تقریب ضریب GDOP استفاده از SVR بود که توسط Wu و همکارانش ارائه شد [۷]. این روش بر خلاف روش شبکه عصبی از ریسک ساختاری بهره می‌برد. وقتی که از این مدل‌ها استفاده می‌شود تعیین ساختار ANN، تعیین وزن‌ها و بهینه‌سازی وزن‌ها، تعیین نوع تابع کرنل SVM و انتخاب گام به گام شاخص‌های آزاد آن همواره مسأله است. در روش SVR از جستجو هدایت شده برای تعیین شاخص‌های SVM استفاده شده است. دکتر موسوی روش ACOA را برای این منظور استفاده کرد [۹] که بدون استفاده از ماتریس معکوس تمام زیر مجموعه ماهواره‌ها را محاسبه کرده و پیچیدگی محاسباتی را کاهش می‌دهد. الگوریتم ژنتیک نیز توسط موسوی برای این منظور ارائه شد [۱۰]. سرعت این روش بالا بود و در مقایسه با شبکه عصبی روش سریع‌تر و

برقرار است. بردار $(e_{i1}, e_{i2}, e_{i3}) \equiv E_i, i=1,2,\dots,n$ نشان‌دهنده بردار line-of-sight از کاربر به ماهواره است. رابطه (۳) به شکل زیر بازنویسی می‌شود:

$$z = Gx + v \quad (4)$$

راه حل کوچک‌ترین مجذور برای معادله شبه فاصله خطی GPS، (معادله ۴) به شکل زیر ارائه شده است:

$$\tilde{X} = (G^T G)^{-1} G^T z \quad (5)$$

در معادله (۴) ابعاد ماتریس هندسی G $n \times 4$ است که در آن $n > 4$ خواهد بود. کیفیت راه حل ناوبری برای معادله شبه فاصله خطی با به دست آوردن تفاوت موقعیت‌های صحیح و تقریبی به شکل معادله (۶) است:

$$\tilde{X} = (G^T G)^{-1} G^T v \quad (6)$$

در رابطه اخیر v و X متوسط صفر دارند. کوواریانس بین خطاها در اجزای موقعیت تخمین زده شده برابر است با:

$$E\{\tilde{x}\tilde{x}^T\} = (G^T G)^{-1} G^T E\{vv^T\} G (G^T G)^{-1} \quad (7)$$

که در آن $E\{0\}$ عملگر امید ریاضی است. اگر تمام اجزای V دو به دو ناهمبسته و واریانس σ^2 داشته باشند.

بنابراین، $E\{vv^T\} = \sigma^2 I$ و در نتیجه:

$$E\{\tilde{x}\tilde{x}^T\} = \sigma^2 (G^T G)^{-1} \quad (8)$$

بهترین حالت هندسی ماهواره‌ها وقتی حاصل می‌شود که ماهواره‌ها با حداکثر فاصله از هم در فضا قرار گرفته باشند. تأثیرهای هندسی ماهواره‌ها با یک عدد تک بعدی به نام DOP اندازه‌گیری و تعریف می‌شود. هر چه مقدار این عامل کمتر باشد وضعیت هندسی بهتری حاصل خواهد شد. تغییرات نسبی ماهواره‌ها و گیرنده‌ها موجب تغییر مقدار DOP خواهد شد. تغییر DOP بیشتر جز دو مورد به کندی است، وقتی که ماهواره از دید گیرنده خارج شود و وقتی که بین ماهواره و گیرنده موانع وجود داشته باشد [۱۲]. با توجه به نیاز کاربر انواع مختلفی از DOP وجود دارد، ترکیب DOP مکان با DOP زمانی DOP هندسی را شکل می‌دهد [۹]. در این مورد ماتریس G به شکل رابطه (۹) تعریف

دقیق‌تری در شبیه‌سازی‌ها نشان داده است. استفاده از محاسبات تکاملی توسط رنجبر و همکارانش به‌تازگی در زمینه تخمین GDOP ارایه شده است [۱۱].

۳- عامل GDOP

شکل (۱) ارتباط بین ماهواره‌ها، مرکز زمین و کاربر مکان‌یابی را مشخص می‌کند. در این شکل بردار s نشان‌دهنده ارتباط بین مرکز زمین با یک ماهواره است. بردار u نشان‌دهنده ارتباط از مرکز زمین به کاربر است. همچنین، بردار r نشان‌دهنده ارتباط از کاربر به ماهواره است [۱۲]. ارتباط بین این بردارها با معادله (۱) توصیف می‌شود:


$$r = s - u \quad (1)$$

فاصله r از طریق زمان انتشار سیگنال مابین ماهواره تا گیرنده GPS کاربر تعیین می‌شود. شبه فاصله GPS برای هر ماهواره مطابق با رابطه (۲) است.

$$\rho_i = \|s_i - u\| + c$$

$$t_b + v_{\rho t} = \sqrt{(x_i - x_u)^2 + (y_i - y_u)^2 + (z_i - z_u)^2} + c_{t_b} + v_{\rho t} \quad (2)$$

در این معادله، (x_i, y_i, z_i) و (x_u, y_u, z_u) به ترتیب نشان دهند مکان کاربر و مکان ماهواره در سه بعد هستند. شاخص C نشان دهنده سرعت نور و $v_{\rho t}$ نشان‌دهنده نویز اندازه‌گیری شبه‌فاصله است.



شکل (۱): ارتباط بین ماهواره، گیرنده مرکز زمین

با تعریف $\hat{\rho}_i$ و با توجه به رابطه (۲) خواهیم داشت:

$$\Delta \rho_i = \rho_i - \hat{\rho}_i = e_{i1} \Delta x_u + e_{i2} \Delta y_u + e_{i3} \Delta z_u + c_{t_b} + v_{\rho} \quad (3)$$

در رابطه (۳) $e_{i1} = \frac{x_n - x_1}{\hat{r}_1}$ ، $e_{i2} = \frac{y_n - y_2}{\hat{r}_2}$

$$e_{i3} = \frac{z_n - z_3}{\hat{r}_3} \text{ و } \hat{r}_i = \sqrt{(x_i - x_u)^2 + (y_i - y_u)^2 + (z_i - z_u)^2}$$

$$f_3(\vec{\lambda}) = \lambda_1^3 + \lambda_2^3 + \lambda_3^3 + \lambda_4^3 = \text{trace} \left[(G^T G)^3 \right] \quad (14)$$

$$f_4(\vec{\lambda}) = \lambda_1 \lambda_2 \lambda_3 \lambda_4 = \det(G^T G) \quad (15)$$

چهار نقشه مختلف به این شکل است که:

نقشه اول، چهار ورودی و چهار خروجی:

$$\text{Input} : (x_1, x_2, x_3, x_4)^T = (f_1, f_2, f_3, f_4)^T \quad (16)$$

$$\text{Output} : (y_1, y_2, y_3, y_4)^T = (\lambda_1^{-1}, \lambda_2^{-1}, \lambda_3^{-1}, \lambda_4^{-1})^T \quad (17)$$

نقشه دوم، ۱۰ ورودی و ۴ خروجی:

$$\text{Input} : (x_1, x_2, x_3, x_4)^T = \quad (18)$$

$$\left((G^T G)_{1,1}, (G^T G)_{1,2}, \dots, (G^T G)_{4,4} \right)^T$$

$$\text{Output} : (y_1, y_2, y_3, y_4)^T = (\lambda_1^{-1}, \lambda_2^{-1}, \lambda_3^{-1}, \lambda_4^{-1})^T \quad (19)$$

نقشه سوم، ۴ ورودی و ۱ خروجی:

$$\text{Input} : (x_1, x_2, x_3, x_4)^T = (f_1, f_2, f_3, f_4)^T \quad (20)$$

$$\text{Output} : y = GDOP \quad (21)$$

نقشه چهارم، ۱۰ ورودی و ۱ خروجی:

$$\text{Input} : (x_1, x_2, x_3, \dots, x_{10})^T = \quad (22)$$


$$\left((G^T G)_{1,1}, (G^T G)_{1,2}, \dots, (G^T G)_{10,10} \right)^T$$

$$\text{Output} : y = GDOP \quad (23)$$

نگاشت به GDOP بسیار غیر خطی است و به شکل

تحلیلی حل نمی‌شود. تعیین آن با مدل SVMPSO و با

آزمایش هر ۴ نقشه انجام می‌شود [۶]، [۹]، [۱۰].



شکل (۲): ارتباطات برای ۴ نقشه محاسبه GDOP

۴- ماشین بردار پشتیبان

یکی از پرکاربردترین دسته‌بندی‌کننده‌ها، که برای

نخستین بار در سال ۱۹۹۲ ارایه شد، ماشین بردار پشتیبان

می‌شود:

$$G = \begin{bmatrix} \cos(E1) * \sin(AZ1) & \cos(E1) * \cos(AZ1) & \sin(E1) & 1 \\ \cos(E2) * \sin(AZ2) & \cos(E2) * \cos(AZ2) & \sin(E2) & 1 \\ \cos(E3) * \sin(AZ3) & \cos(E3) * \cos(AZ3) & \sin(E3) & 1 \\ \cos(E4) * \sin(AZ4) & \cos(E4) * \cos(AZ4) & \sin(E4) & 1 \end{bmatrix} \quad (9)$$

جایی که E و AZ به ترتیب ارتفاع و زاویه ماهواره

است. عامل GDOP از رابطه زیر حاصل می‌شود:

$$GDOP = \sqrt{\text{trace}(G^T G)^{-1}} = \sqrt{\frac{\text{trace}[\text{adj}(G^T G)]}{\det(G^T G)}} \quad (10)$$

این عامل مشخص می‌کند که چقدر یک واحد از خطای

اندازه‌گیری در خطای موقعیت برای نقطه‌ای با مختصات

مشخص دخیل است. تعیین دقیق ماهواره‌ها بر اساس

ضریب GDOP به دقت بیشتر در مکان‌یابی منجر می‌شود.

از آنجا که $G^T G$ یک ماتریس 4×4 می‌باشد و دارای ۴

مقدار ویژه به ازای λ_i ($i=1,2,3,4$) است، مشخص است

که ۴ مقدار ویژه ماتریس λ_i^{-1} خواهد بود. براساس این

واقعیت رابطه (۲) به شکل زیر بازنویسی می‌شود:

$$GDOP = \sqrt{\lambda_1^{-1} + \lambda_2^{-1} + \lambda_3^{-1} + \lambda_4^{-1}} \quad (11)$$

بر اساس ارتباط بین ورودی و خروجی ۴ نقشه برای

GDOP قابل اجرا است. جدول (۱) و شکل (۲) این ۴

نقشه را مشخص می‌کند.

جدول (۱): ساختار ۴ نقشه محاسبه عامل GDOP

نقشه	ارتباط	تعداد ورودی	تعداد خروجی
۱	$R^4 \rightarrow R^4$	۴	۴
۲	$R^{10} \rightarrow R^4$	۱۰	۴
۳	$R^4 \rightarrow R^1$	۴	۱
۴	$R^{10} \rightarrow R^1$	۱۰	۱

نگاشت با تعریف ۴ متغیر به شکل زیر انجام می‌شود

[۱۲].

$$f_1(\vec{\lambda}) = \lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = \text{trace}(G^T G) \quad (12)$$

$$f_2(\vec{\lambda}) = \lambda_1^2 + \lambda_2^2 + \lambda_3^2 + \lambda_4^2 = \text{trace} \left[(G^T G)^2 \right] \quad (13)$$

c و v شاخص‌های تابع زیگموییدی $S[(X, X_i)]$ هستند به نحوی که نامعادله $c \geq v$ برقرار باشد. فرآیند یادگیری برای ایجاد توابع تصمیم‌گیری دارای ساختاری دو لایه است. با استفاده از تئوری بهینه‌سازی برای طبقه‌بندی و بر اساس تئوری یادگیری آماری، SVM خطای طبقه‌بندی را به حداقل می‌رساند [۱۹]، [۲۰].

۴-۱- مدل رگرسیونی SVM

در ابتدا از SVM فقط برای دسته‌بندی استفاده می‌شد اما بعدها از این مدل در عملیات رگرسیونی نیز بهره گرفته شد [۱۵]. مسأله رگرسیون در SVM یک تابع خطی به شکل $f(x) = \langle w, x \rangle + b$ است. این تابع بر روی یک مجموعه شامل l نمونه مانند $\{(x_1, y_1), \dots, (x_l, y_l) \in R^N, y \in R\}$ می‌تواند مقدار خروجی را بر مبنای مقادیر ورودی تخمین بزند. در رابطه یاد شده x بردار مقادیر ورودی است. شاخص‌های w و b نیز شاخص‌های کنترل تابع f هستند. $\langle w, x \rangle$ نشان‌گر ضرب داخلی است. برای حل مسأله رگرسیون تابع تلفات Vapnik که در آن حداقل خطایی به میزان ε قابل صرف نظر کردن است، در نظر گرفته می‌شود. تابع تلفات به شکل زیر تعریف می‌شود [۲۱]:

$$L_\varepsilon(y) = \begin{cases} |f(x) - y|_\varepsilon = 0 & \text{for } |f(x) - y| < \varepsilon \\ |f(x) - y| = \varepsilon & \text{otherwise} \end{cases} \quad (27)$$

$L_\varepsilon(y)$ معرف تابع تلفات و ε میزان خطای مجاز در تابع تلفات است. شاخص‌های کنترل کننده تابع رگرسیون بهینه با حل مسأله بهینه‌سازی زیر حاصل می‌شوند [۲۲]:

$$\text{Minimise } \phi(w, \xi, \xi^*) = \frac{1}{2} |w|^2 + c \sum (\xi_i^* + \xi_i) \quad (28)$$

$$y_i - ((w, x_i) + b) \leq \varepsilon + \xi_i \quad (29)$$

$$\text{Subject to } ((w, x_i) + b) - y_i \leq \varepsilon + \xi_i^* \quad (30)$$

$$\xi_i^*, \xi_i \geq 0$$

در روابط بالا ξ_i^*, ξ_i متغیرهای slack هستند. این متغیرها به همراه تابع تلفات در شکل (۳) نشان داده شده‌اند. برای حل مسأله بهینه‌سازی بالا به کمک تئوری لاگرانژ، تابع

است. این مدل توسط Vapnic و Cortes ارائه شده است. این مدل در مواجهه با نمونه‌های آموزشی محدود عملکرد مناسبی دارد و نسبت به مدل‌های مشابه دارای قدرت تعمیم‌پذیری بالایی است. در این مدل از اصول کمینه‌سازی ریسک ساختاری استفاده شده است، در حالی که سایر روش‌ها از اصول کمینه‌سازی ریسک تجربی بهره می‌برند. ثابت شده است که ریسک ساختاری عملکرد بهتری نسبت به ریسک تجربی دارد [۱۳]. مدل SVM نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کند [۱۴]. حداکثر کردن حاشیه ابر صفحه به حداکثر شدن تفکیک بین طبقات منجر و به نزدیک‌ترین نقاط آموزشی بردارهای پشتیبان اطلاق می‌شود. تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود. اگر نقاط آموزشی به شکل $[x_i, y_i]$ و بردار ورودی $x_i \in R^n$ و ارزش طبقه $y_i \in (-1, 1)$ تعریف شود، آنگاه در حالتی که داده‌ها به شکل خطی قابل تفکیک هستند، قواعد تصمیم‌گیری که تعریف می‌شود، به شکل معادله زیر است:

$$y = \text{sign} \left(\sum_{i=1}^N y_i \alpha_i (X, X) + b \right) \quad (24)$$

که در آن y خروجی معادله، y_i ارزش طبقه نمونه آموزشی و نشان‌دهنده ضرب داخلی است. بردار $X = (x_1, x_2, \dots, x_n)$ نشان دهنده یک داده ورودی و بردارهای $X_i (i=1, \dots, N)$ بردارهای پشتیبان هستند. در معادله (۲۴)، شاخص‌های b و α_i تعیین‌کننده ابر صفحه هستند. اگر داده‌ها به شکل خطی قابل تفکیک نباشند، معادله (۲۴) به معادله زیر تغییر پیدا می‌کند:

$$y = \text{sign} \left(\sum_{i=1}^N y_i \alpha_i K(X, X_i) + b \right) \quad (25)$$

تابع $K(X, X_i)$ ، تابع کرنل است. در این مقاله، از تابع کرنل RBF استفاده شده است:

$$K(X, X_i) = \exp \left(-\frac{1}{\sigma^2} (X - X_i)^2 \right) \quad (26)$$

که در آن σ پهنای باند کرنل تابع پایه شعاعی است و

SVM به آسانی قابل گسترش به رگرسیون غیر خطی است. بدین منظور از توابع کرنل استفاده می‌شود. بدین ترتیب در حالت رگرسیون غیر خطی در SVM شاخص‌های کنترل کننده تابع بهینه با روابط زیر محاسبه می‌شوند [25]:

$$w_0 \cdot x = \sum_{\text{support vector}} (\alpha_i^* - \alpha_i) K(x_i, x) \quad (36)$$

$$b_0 = -\frac{1}{2} \sum_{\text{support vector}} (\alpha_i^* - \alpha_i) \quad (37)$$

$$[K(x_r, x_r) + K(x_s, x_s)]$$

در روابط بالا K نشان دهنده کرنل است.

4-2- بیان مسأله

مدل SVM دارای یک اشکال است که استفاده از آن را در محیط‌های پژوهشی و صنعتی محدود کرده است [16]. کیفیت واقعی الگوریتم SVM وابستگی کاملی به تنظیم عامل‌های آن و همچنین، شاخص‌های کرنل دارد. بنابراین، بسیار ضروری است از روشی سریع، واقعی و خودکار برای بهینه‌سازی شاخص‌های SVM استفاده شده و از خطای تعمیم SVM کاسته شود [17]. انتخاب کمتر از مقدار درست C باعث عدم تعادل بین ریسک ساختاری و ریسک تجربی می‌شود. کم بودن ϵ بر روی ساختار مدل اثرگذار است و زیاد بودن آن باعث کاهش عملکرد است. اگر مقدار شاخص σ کم باشد SVM با انباشتگی اطلاعات ورودی مواجه خواهد شد و اگر زیاد باشد SVM انعطاف لازم را برای حل مسائل پیچیده نخواهد داشت [18]. وقتی از یک روش جستجو هدایت شده استفاده شود یا باید محدوده شاخص‌های جستجو افزایش یابد و یا این‌که باید اندازه گام‌های جستجو برای افزایش دقت و پیدا کردن راه حل مطلوب افزایش یابد. این امر باعث کاهش قابلیت اطمینان و افزایش زمان می‌شود.

4-3- روش بهینه‌سازی گروهی ذرات

از PSO برای رسیدن به ساختار بهینه SVM به شکل خودکار استفاده می‌شود، روش PSO، یک روش بهینه‌سازی است که از رفتار جمعی پرندگان در پیدا کردن غذا الهام


لاگراژ مطابق با رابطه (31) نوشته می‌شود.

$$L(\alpha^*, \alpha) = -\epsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) + \sum_{i=1}^l y_i (\alpha_i^* + \alpha_i) - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* + \alpha_i) (\alpha_j^* + \alpha_j) (x_i x_j) \quad (31)$$

با بیشینه شدن تابع فوق تحت محدودیت‌های زیر، مقادیر α^*, α بدست می‌آیند.

$$\begin{cases} \sum \alpha_i^* = \sum \alpha_j \\ 0 \leq \alpha_i^* \leq C \text{ for } i=1,2,\dots \\ 0 \leq \alpha_i \leq C \end{cases} \quad (32)$$

مسأله بهینه‌سازی بالا به کمک روش‌های QP قابل حل است. داده‌هایی که ضرایب لاگراژ متناظر با آن‌ها غیر صفر باشد، به عنوان بردار پشتیبان شناخته می‌شوند [23]. از نظر هندسی این داده‌ها دارای خط‌های پیش‌بینی بزرگتر از $\pm \epsilon$ هستند، بنابراین، بردارهای پشتیبان در درون باند $\pm \epsilon$ قرار نمی‌گیرند، پس مقدار ϵ تعداد بردارهای پشتیبان را کنترل می‌کند [24]. به کمک ضرایب لاگراژ و بردارهای پشتیبان، شاخص‌های کنترل کننده پاسخ بهینه نیز به شکل (23) تا (35) محاسبه می‌شوند [25]:



شکل (3): تابع تلفات Vapnik و متغیرهای slack [24]

$$w_0 = \sum_{\text{support vector}} (\alpha_i^* - \alpha_i) x_i \quad (33)$$

$$b_0 = -\frac{1}{2} w_0 [x_r + x_s] \quad (34)$$

$$f(x) = \sum_{\text{support vector}} (\alpha_i^* - \alpha_i) (x_i - x_j) + b_0 \quad (35)$$

در روابط بالا x_r, x_s دو بردار پشتیبان هستند. برای ساخت مدل ماشین بردار پشتیبان، شاخص‌های C و ϵ توسط کاربر تعریف می‌شوند. شاخص ϵ نیز می‌تواند مقادیر صفر تا بی‌نهایت را بپذیرد. مسأله رگرسیون خطی در

$$0 \leq \frac{\phi_1 + \phi_2}{2} - 1 < \omega < 1 \quad (۴۲)$$

که در آن $\phi_1 = C_1.rand$ و $\phi_2 = C_2.rand$ هستند. برای جلوگیری از واگرایی الگوریتم، معمولاً مقدار نهایی سرعت هر ذره به یک مقدار بیشینه محدود می‌شود. یعنی $v_{id} \in [-v_{min}, v_{max}]$. شرط خاتمه الگوریتم همگرایی آن یا توقف بعد از تعداد معینی تکرار است. شایستگی هر ذره با استفاده از تابع برازندگی، $f(0)$ ، سنجیده می‌شود. این تابع برازندگی مربوط به مسأله مورد نظر بوده و هدف کمینه کردن آن است. بهترین موقعیت هر ذره λ_m در هر تکرار طبق رابطه (۴۳) به هنگام می‌شود:

$$P_i(t) = \begin{cases} P_i(t-1) & \text{if } f(y_i(t)) \geq f(P_i(t-1)) \\ y_i(t) & \text{if } f(y_i(t)) \leq f(P_i(t-1)) \end{cases} \quad (۴۳)$$

این رابطه به این معناست که اگر مقدار فعلی تابع برازندگی ذره λ_m ، به ازای موقعیت فعلی y_i ، از برانده‌ترین مقدار قبلی آن کمتر باشد، همین موقعیت به عنوان بهترین موقعیت این ذره ثبت می‌شود و در غیر این صورت بهترین موقعیت ذره، بهترین موقعیت قبلی باقی خواهد ماند [۲۸]. فلوچارت الگوریتم PSO در شکل (۴) دیده می‌شود. هر ذره دارای یک مکان تصادفی با فضای D بعدی و سرعت تصادفی در هر بعد است، هر ذره مورد ارزیابی قرار می‌گیرد، اگر ارزیابی هر ذره بهتر از بهترین ارزش ذرات بود، بردار مکان برای هر ذره ذخیره شود. اگر ارزش ذره در ارزیابی بهتر از بهترین کلی ذرات بود بردار مکان برای بهترین کلی ذخیره شود. سرعت و مکان ذره تا تصدیق شرایط پایانی به روز می‌شود. برای الگوریتم PSO ۳۰ ذره به طور تصادفی تولید شد. ضرایب C_1 و C_2 به ترتیب ۲/۳ و ۱/۸ تعیین شد و وزن اینرسی ω به طور خطی بین ۰/۹ تا ۰/۵ کاهش پیدا کرد. حداکثر تعداد نمونه‌ها ۲۰۰ انتخاب شد. مقادیر شاخص c جستجو شده بین ۰/۰۱ و ۳۵۰۰۰ است، در حالی که مقدار شاخص σ بین ۰/۰۰۰۱ و ۳۲ بوده است. مدل PSO برای تعیین شاخص‌های SVM به شکل شکل (۵) استفاده شد [۲۹]:

گرفته شده است. در این روش هر نامزد برای جواب مسأله، یک پرنده در فضای جستجو است که ذره نام دارد. هر ذره دارای یک مقدار شایستگی است که توسط تابع شایستگی مسأله به دست می‌آید. پرنده‌ای که به غذا نزدیک‌تر است شایستگی بیشتری دارد [۲۶]. این روش مانند بیشتر روش‌های جستجو با یک گروه از جواب‌های تصادفی جستجو را به شکل موازی شروع می‌کند و سپس، برای یافتن جواب بهینه در فضای مسأله با به هنگام کردن مکان ذره‌ها به جستجو ادامه می‌دهد. در روش بهینه‌سازی گروه ذرات برای هر ذره i ، یک موقعیت y_i و یک سرعت v_i در نظر گرفته می‌شود. اگر بعد مسأله بهینه‌سازی n فرض شود، بردار موقعیت و بردار سرعت i به شکل زیر است [۳۷]:

$$y_i = [y_{i1}, y_{i2}, \dots, y_{in}] \quad (۳۸)$$

$$v_i = [v_{i1}, v_{i2}, \dots, v_{in}] \quad (۳۹)$$

که در آن v_{id} و y_{id} به ترتیب معرف موقعیت مکانی و سرعت بعد d م ذره i است. سرعت و موقعیت این بعد ذره در تکرار $(t+1)$ به شکل روابط (۴۰) و (۴۱) است.

$$v_{id}(t+1) = \omega v_{id}(t) + C_1.rand(P_{id}(t) - y_{id}(t)) + C_2.rand(\bar{P}_{id}(t) - y_{id}(t)) \quad (۴۰)$$

$$y_{id}(t+1) = y_{id}(t) + v_{id}(t+1) \quad (۴۱)$$

در روابط بالا، ω وزن اینرسی در بازه $[0, 1]$ ، C_1 و C_2 ضرایب یادگیری یا شتاب در بازه $[1, 2]$ هستند. C_2 را شاخص اجتماعی و C_1 را شاخص شناختی می‌گویند و معمولاً این دو با هم برابر هستند. Rand عدد تصادفی با توزیع یکنواخت در بازه $[0, 1]$ ، بهترین موقعیت ذره در بعد d م تاکنون و \bar{P}_{id} بهترین موقعیت در بین کل ذره‌ها برای بعد d م تاکنون و P_{id} بهترین موقعیت ذره در بین کل ذره‌ها برای بعد d م تا به حال است. ω برای ایجاد توازن لازم بین یافتن پاسخ کلی و محلی در رابطه بالا وارد شده است. ثابت شده است که شرط همگرایی الگوریتم آن است که رابطه (۴۲) برقرار باشد.

۵- پیاده‌سازی و شبیه‌سازی

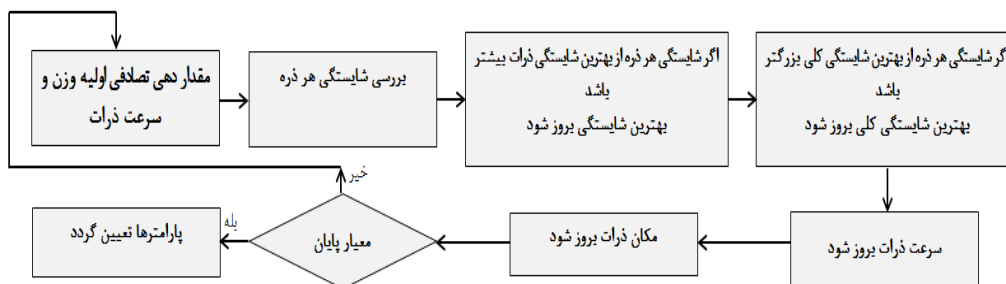
۵-۱- پیاده‌سازی

برای تغییر آن باید ترکیب ماهواره دچار تغییر شود و این مستلزم حرکت آن‌ها و قرارگیری آن‌ها در مکان مناسب به لحاظ هندسی است، زمان دریافت اطلاعات گیرنده روی ۱ دقیقه تنظیم شد. اطلاعات ورودی مربوط به محاسبات GDOP در پیام Satellite Status پروتکل UBX گیرنده U-blox قرار دارد، اطلاعات مهم این پیام که برای پیاده‌سازی مدل ضروری است در جدول (۲) نشان داده شده است. این اطلاعات مطابق با ساختار این پیام با استفاده از نرم‌افزار MATLAB رمزگشایی، تجزیه شده و سپس، مطابق با روابط بخش ۳ به عنوان ورودی مدل PSOSVM برای تقریب مقادیر دقیق GDOP در چهار نوع مختلف استفاده شد، مدل PSOSVM نیز مقادیر GDOP را تقریب می‌زند. مقادیر GDOP که توسط الگوریتم داخلی گیرنده محاسبه می‌شود در پیام NAV-DOP پروتکل UBX گیرنده قرار دارد، نرم‌افزار MATLAB این اطلاعات را نیز با فرمان که از طریق درگاه سریال گیرنده به آن اعمال می‌شود دریافت می‌کند و با مقادیر محاسبه شده با مدل PSOSVM مقایسه شد.

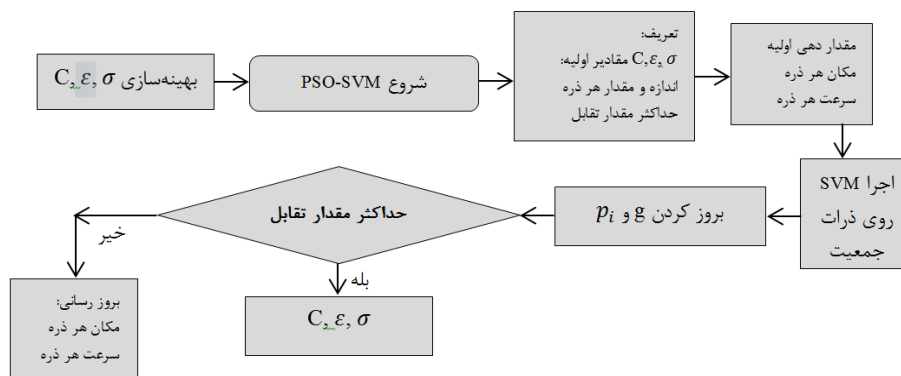
به منظور نشان دادن کیفیت و حسن عملکرد مدل SVMPSO در دسته‌بندی و تخمین مقادیر GDOP، آزمایش‌هایی طراحی شد. از یک گیرنده GPS مدل U-LEA-6H blox برای جمع‌آوری اطلاعات استفاده شد. از ویژگی‌های بارز این گیرنده ۵۰ کاناله بودن، قابلیت ردیابی ۱۶ ماهواره به طور همزمان و دقت مکان‌یابی ۵ متر است. در شکل (۶) تصویر گیرنده همراه با برد جانبی که قابلیت اتصال به درگاه‌های USB و RS232 را دارد نشان داده شده است. از درگاه سریال برای ارتباط با نرم‌افزار MATLAB استفاده می‌شود. این گیرنده با استفاده از USB به کامپیوتر شخصی متصل می‌شود [۳۰]. اطلاعات در آزمایشگاه GPS دانشگاه تربیت دبیر شهید رجایی جمع‌آوری شده است. مختصات دقیق نقطه‌ای که گیرنده GPS در آن مکان قرار گرفته و نمونه‌برداری انجام شده به شکل زیر است:

$$(x_p = 3226206.54 \quad y_p = 4054570.23 \quad z_p = 3709308.12)$$

با توجه به اینکه تغییر عامل GDOP به کندی است و



شکل (۴): ساختار الگوریتم PSO



شکل (۵): ساختار مدل PSOSVM

مبنای GDOP وجود دارد: روش دسته‌بندی و روش تخمین.

دسته‌بندی GDOP برای انتخاب یک زیر مجموعه قابل انتخاب (که عامل GDOP به اندازه کافی کوچک باشد) از ماهواره‌ها انجام می‌شود. تقریب GDOP محاسبه این عامل از روی اطلاعات وردی گیرنده GPS و مطابق با چهار نقشه تشریح شده است.

۵-۲-۱- بررسی عملکرد مدل در تقریب GDOP

عملکرد تقریب GDOP مدل استفاده شده با استفاده از شاخص‌های جدول (۳) بررسی شد. هدف اصلی، مقایسه ۴ نقشه مختلف محاسبه GDOP با یکدیگر و همچنین، سنجش کارایی مدل SVMPSO و مقایسه آن با سایر مدل‌هایی است که به تازگی به این منظور استفاده شده‌اند. در این شاخص‌ها متغیر x_i عامل GDOP حاصل شده از ماتریس معکوس و x_i' مقدار عامل GDOP خروجی مدل PSOSVM است. در این شاخص‌ها متغیر n تعداد داده‌های آزمون را نشان می‌دهد.

جدول (۳): معیارهای مورد استفاده در سنجش عملکرد مدل

PSOSVM در تخمین مقادیر GDOP

Title	Equation
Mean Square Error(MSE)	$\frac{1}{n} \sum_{i=1}^n (x_i - x_i')^2$
Mean Absolute Error(MAE)	$\frac{1}{n} \sum_{i=1}^n x_i - x_i' $
Root Mean Square Error(RMSE)	$\sqrt{\frac{1}{M} \sum_{i=1}^M (x_i - x_i')^2}$
Mean Absolute Percentage Error(MAPE)	$\frac{1}{n} \sum_{i=1}^n \left \frac{x_i - x_i'}{x_i} \right $

در شکل (۸)، GDOP محاسبه شده با ماتریس معکوس با رنگ قهوه‌ای و مقادیر GDOP محاسبه شده با نقطه‌های مشکی نشان داده شده است. مدل استفاده شده در این شبیه‌سازی، نقشه نوع ۱ محاسبه ضریب GDOP است.

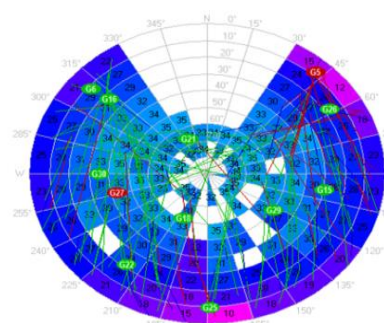
جدول (۲): پیام اطلاعات ماهواره‌ها

ساختار پیام	سرآغاز	طول پیام
مکان	0xF1 0x03	5 + 6*GT
۰	شناسه پروتکل	توضیح
۱	شناسه پیام	
۲	تعداد ماهواره تحت دید (n)	
n.۶+۳	شناسه ماهواره	
n.۶+۴	وضعیت ماهواره	
n.۶+۵	زوایه ماهواره	
n.۶+۶	ارتفاع ماهواره	

شکل (۷) گراف هندسی ماهواره‌های GPS را که توسط گیرنده GPS انتخاب شده است، برای ۳۰۰۰ نمونه نشان می‌دهد. شبیه‌سازی با استفاده از یک پردازنده *i52.5GHz CORE™* انجام شده است.



شکل (۶): گیرنده GPS U-blox LEA-6H



شکل (۷): گراف هندسی ماهواره‌های GPS

۵-۲- آزمایش‌ها

به طور کلی دو راهکار برای تعیین هندسه ماهواره بر

دیگر کمتر است. جدول (۴) دقت مدل PSOSVM را بر اساس معیارهای سنجش تعریف شده نشان می‌دهد. از این جدول مشخص است که دقت نقشه نوع سوم بهتر از سایر نقشه‌هاست و پس از آن نقشه نوع اول دارای بهترین دقت است. عملکرد نقشه‌ی نوع چهارم نسبت به سایر نقشه‌ها ضعیف‌تر بوده است. مقایسه مدل PSOSVM با سایر مدل‌هایی که برای تخمین GDOP استفاده شده‌اند در جدول (۴) نشان داده شده است. با توجه به شاخص‌های تعریف شده اساسی برای مدل SVR، بهترین دقت حاصل شده برای این مدل که برای نوع سوم و با ۴ ورودی است تقریباً ۰/۴ است. این مدل با مدل‌های دیگر شامل مدل NN، GA نیز مقایسه شد. مدل GA نیز نسبت به سه مدل دیگر دارای سرعت بهتری است و نسبت به NN دقیق‌تر است. مدل SVM تعمیم‌پذیری بهتری نسبت به GA و NN دارد. اما روش SVM چون از جستجوی هدایت شده و غیر خوارکار استفاده می‌کند دقت کمتری نسبت به PSOSVM دارد. در مدل PSOSVM بین سرعت و دقت توازن برقرار است.

جدول (۴): مقایسه روش PSOSVM با مدل NN، GA و


SVM به لحاظ سرعت و دقت

معیار	نقشه ۱	نقشه ۲	نقشه ۳	نقشه ۴
MAE	۰/۱۷	۰/۱۴	۰/۱۳	۰/۴۵
MAPE	۷	۱۱	۶	۱۷
MSE	۰/۰۵	۰/۰۳	۰/۰۲	۰/۲۹
STD	۰/۲۲۶	۰/۳۴۵	۰/۱۸۸	۰/۵۳۸
MEAN	-۰/۰۳۹	۰/۰۵۶	۰/۰۲۷	-۰/۰۲۱
MIN	۰/۰۰۰۰۴	۰	۰	۰/۰۰۱۸
MAX	-۱/۰۱	۱/۰۵	۰/۶۷	۱/۵۷
RMS	۰/۲۲۹	۰/۳۶۲	۰/۱۶۶	۰/۵۳۸


قسمت (ب) همین شکل، شبیه‌سازی نقشه نوع دوم محاسبه GDOP آمده است که GDOP محاسبه شده با مدل PSOSVM، با نقاط بنفش مشخص شده است. به ترتیب در همین شکل و در قسمت‌های (ج) و (د) نقشه‌های نوع سوم و چهارم محاسبه GDOP با نقاط رنگی سبز و آبی نمایان شده‌اند. به منظور مقایسه GDOP محاسبه شده در هر ۴ نوع با یکدیگر و روش ماتریس معکوس شبیه‌سازی، شکل (۶) قسمت (ه) منعکس شده است. شایان ذکر است که هر نوع، دارای پیچیدگی خاصی است، به گونه‌ای که نقشه‌های نوع ۱ و ۳ از شاخص‌های کمتری نسبت به نوع ۲ و ۴ بهره می‌برند، زیرا در نوع ۱ و ۳ از ۴ ورودی استفاده می‌شود در حالی که در نوع ۲ و ۴ از ۱۰ ورودی بهره می‌برد. تفاوت نوع ۲ و ۴ در این است که ورودی‌ها در نوع ۴ مستقیم و در نوع ۲ غیر مستقیم‌اند که موجب می‌شود تعداد شاخص‌های نوع ۴ از نوع ۲ کمتر شود. نتیجه‌ای که حاصل می‌شود این است که در نقشه چهارم بین ورودی و خروجی‌ها ارتباط آسان‌تری برقرار است. خطای محاسبه GDOP با استفاده از رابطه زیر به دست می‌آید:

$$E = GDOP (by matrix) - GDOP (by approximated) \quad (۴۴)$$


در شکل (۹) خطای محاسبه GDOP توسط مدل SVMPSO و در نوع‌های ۱، ۲، ۳ و ۴ به ترتیب به رنگ‌های مشکی، سبز، بنفش و آبی نشان داده شده است. به منظور بررسی خطای محاسبه در شکل (۹) قسمت (ه)، خطاهای محاسبه این ۴ نوع با هم مقایسه شده‌اند. مطابق با این شکل خطای حاصل از نقشه نوع سوم کمتر و پایدارتر از سایر نقشه‌هاست. نقشه نوع سوم برای محاسبه مستقیم GDOP مناسب‌تر است. نقشه‌های ۴ ورودی، نوع ۱ و نوع ۳، عملکرد بهتری نسبت به نقشه‌های ۱۰ ورودی، نوع ۲ و ۴ دارند. با توجه به شکل ۹-خطای نوع سوم از ۳ نقشه




(ب)




(الف)



(د)




(ج)




(ه)

شکل (۸): تخمین GDOP با روش SVMPSO و مقایسه با روش ماتریس معکوس


الف- محاسبه با نقشه اول ب- محاسبه نقشه دوم ج- محاسبه با نقشه سوم د- محاسبه با نقشه چهارم




(ب)




(الف)



(د)



(ج)



(ه)

شکل (۹): خطای تخمین GDOP با مدل SVMPSO

الف- خطای محاسبه با نوع اول ب- خطای محاسبه نوع دوم ج- خطای محاسبه با نوع سوم د- خطای محاسبه با نوع چهارم

دقت مدل PSOSVM ۹۹/۹۵ درصد است. این مدل را با مدل SVM که از PSO بی‌بهره است مقایسه کردیم. همچنین، مدل PSOSVM با مدل GA و NN که پیش از این استفاده شده است مقایسه شد. نتایج این بررسی در جدول (۸) منعکس شده است. مطابق با این بررسی مدل ارائه شده بهترین دقت را داراست. پس از آن، مدل GA از دقت خوبی برخوردار است.

جدول (۸): مقایسه مدل PSOSVM با مدل‌های GA، NN و SVM

SVM				
PSOSVM	NN	GA	SVM	الگوریتم
۹۹/۹	۹۱	۹۹/۶	۹۸/۴	CA

۶- نتیجه‌گیری

به منظور بهبود عملکرد دقت گیرنده‌های GPS به‌ویژه گیرنده‌های ارزان قیمت کمینه‌سازی ضریب GDOP اهمیت فراوانی دارد. از میان همه ماهواره‌هایی که گیرنده می‌بیند، یک دسته از ماهواره‌ها، که بهترین حالت هم‌دوسی را دارد باید انتخاب شود تا ضریب GDOP کم شود. در این مقاله، از روش PSOSVM برای مدل‌سازی GDOP استفاده شده است. در مقایسه با GA، NN و SVM مدل یاد شده دقیق‌تر و سریع‌تر است. عملکرد تخمین‌زنی و دسته‌بندی این مدل کامل و بسیار مؤثر بود. دقت دسته‌بندی مدل ۹۹/۹ درصد و دقت مدل در تقریب مقادیر GDOP کمتر از ۰/۱۶ بود.

مراجع

- [1] Indriyatmoko, A., Kang, T., Lee, T. Y, J., Lee G. I., Cho, Y. B., Kim, J., "Artificial Neural Networks for Predicting DGPS Carrier Phase and Pseudo-Range Correction", Journal of GPS Solutions; Vol. 12, No. 4, pp. 237-247, 2008.
- [2] Zhang, J., Zhang, K., Grenfell, R., Deakin R., "GPS satellite velocity and acceleration determination using the broadcast ephemeris", Journal of Navigation; Vol. 59, pp. 293-305, 2006.
- [3] Jwo, D. J., "Efficient DOP calculation for GPS with and without altimeter aiding", This Journal; Vol. 54, No. 2, pp. 269-279, 2001.
- [4] Jwo, D. J., Lai, C. C., "Neural network-based

جدول (۵): بررسی آماری خطای تخمین GDOP

شاخص	NN	GA	SVM	PSOSVM
RMSE	۰/۵۰۲	۰/۲۸۳	۰/۴۰۳	۰/۱۶۶
CPU (s)	۰/۰۲۹	۰/۰۱۰	۰/۰۱۴	۰/۰۶۶

۵-۳-۱- بررسی عملکرد دسته‌بندی GDOP با استفاده از مدل PSOSVM

مقدار DOP اگر کمتر از ۲ باشد عالی است. این مقدار نیازمند آنتنی قوی است تا گیرنده بتواند ماهواره‌ها را به خوبی ببیند. مقدار DOP بین ۲ تا ۳ بسیار خوب است. اگر مقدار DOP از ۶ بیشتر شود مکان‌یابی بسیار ضعیف و غیر قابل اطمینان می‌شود. جدول (۶) نرخ DOP را برای حالات مختلف نشان می‌دهد. دسته‌بندی GDOP به منظور انتخاب یک و تنها یک زیر مجموعه‌ی مناسب است. دسته‌بندی با ۵ بردار مشخص به شکل [۰۰۰۰۱]، [۰۰۰۱۰]، [۰۰۱۰۰]، [۰۱۰۰۰]، [۱۰۰۰۰] که به ترتیب نشان دهنده سطح عالی، خوب، متوسط، کمابیش ضعیف و ضعیف می‌باشد تعریف شده است. از معیار CE برای بررسی عملکرد دسته‌بندی استفاده شده است. از جدول (۷) مشخص است که درصد کل CE ۵ است. این مدل دارای خطای بسیار کمی است و مدل بسیار خوبی برای دسته‌بندی به حساب می‌آید. دقت مدل با شاخص CA به شکل زیر محاسبه می‌شود:

$$\sum_{i=1}^m \frac{1}{m} (1 - CE \text{ for any class}) \times 100 \quad (۴۵)$$

جدول (۶): نرخ DOP

DOP Value	binary coding	نرخ	شماره کلاس
$0 < g \leq 2$	00001	عالی	۱
$2 < g \leq 3$	00010	خوب	۲
$3 < g \leq 4$	00100	معتدل	۳
$4 < g \leq 5$	01000	متوسط	۴
> 5	10000	ضعیف	۵

جدول (۷): نتایج دسته‌بندی GDOP با روش GASVM

Cluster	۱	۲	۳	۴	۵	Total	CE
Exc	۳۲۷	۰	۰	۰	۰	۳۲۷	٪۰
Good	۰	۸۲۴	۰	۰	۰	۸۲۴	٪۰
Mod	۰	۱	۱۹۸	۰	۰	۱۹۹	٪۰/۵
Fair	۰	۰	۰	۸۲	۰	۸۲	٪۰
Poor	۰	۰	۰	۰	۶۸	۶۸	٪۰

- No. 3, pp. 388-393, 2010.
- [17] Nizam, M., Mohamed, A., Al-Dabbagh, M., Hussain, A. "Using Support Vector Machine for Prediction Dynamic Voltage Collapse in an Actual Power System", *International Journal of Electrical and Electronics Engineering*; Vol. 37, No. 5, pp. 3730-3736, 2009.
- [18] Shuo, H., Rung-Ching, C., "Using SVM with Financial Statement Analysis for Prediction of Stocks. *Communications of the IIMA*; Vol. 7, No. 4, pp. 63-72, 2007.
- [19] Mohandes, M. A., Halawani, T. O., Rehman, S., Hussain, A. A., "Support vector machines for wind speed prediction", *Renewable Energy*; Vol. 29, No. 6, pp. 939-947, 2004.
- [20] Radhika, Y., Shashi, M., "Atmospheric Temperature Prediction using Support Vector Machines", *International Journal of Computer Theory and Engineering*; Vol. 1, No. 1, pp. 1793-8201, 2009.
- [21] Burgers, C. J. C., "A tutorial on support vector machines for pattern recognition" *Data Mining and Knowledge Discovery*; Vol. 21, No. 3, pp. 121-167, 1999.
- [22] Cao, L. J., Tay, F. E. H., "Support vector machine with adaptive parameters in financial time series forecasting", *IEEE Transactions on Neural Network* Vol. 14, No. 6, pp. 1506-1518, 2003.
- [23] Ganapathiraju, A., "Support vector machines for speech recognition", PhD Thesis, Mississippi State University, USA, 2001.
- [24] Drucker, H., Burges, C., Kaufman, L., Smola, A., Vapnik, V., "Support Vector Regression Machines", MIT Press, Cambridge; Vol. 9, No. 3, pp. 155-161, 1997.
- [25] Smola, A. J., Scolkopf, B., "Tutorial on support vector regression, NeuroCOLT2 technical report series", NC2-TR-1998-03, 1998.
- [26] Lin, S. W., Ying, K. C., Chen, S. C., Lee, Z. J., "Particle swarm optimization for parameter determination and feature selection of support vector machines", *Expert Systems with Applications*, Vol. 35, pp. 1817-1824, 2008.
- [27] Ren, Y., Bai, G., "Determination of Optimal SVM Parameters by Using GA/PSO", *Journal of computers*; Vol. 5, No. 8, pp. 1160-1168, 2010.
- [28] Ardjani, F., Sadouni, K., "Optimization of SVM Multiclass by Particle Swarm (PSO-SVM)", *I. J. Modern Education and Computer Science*; Vol. 2, No. 2, pp. 32-38, 2010.
- GPS GDOP approximation and classification", *Journal of GPS Solutions*; Vol. 11, No. 1, pp. 51-60, 2007.
- [5] Wu, C. H., Ho, Y. W., Chen, L. W., Huang, Y. D., "Discovering approximate expressions of GPS geometric dilution of precision are using genetic programming", *Advances in Engineering Software*; Vol. 45, pp. 332-340, 2012.
- [6] Mosavi, M. R., Azami, H., "Applying Neural Network for Clustering of GPS Satellites", *Journal of Geoinformatics*; Vol. 7, No. 3, pp. 7-14, 2011.
- [7] Wu, C. H., Su, W. H., Ho, Y. W., "A study on GPS GDOP approximation using support vector machines. *IEEE Trans Instrum Meas*; Vol. 60, No. 1, pp. 137-45, 2011.
- [8] Simon, D., Sherief, H., "Navigation satellite selection using neural networks", *Neuron computing*; Vol. 7, No. 1, pp. 247-58, 1995.
- [9] Mosavi, M. R., "An Effective Method for GPS GDOP Clustering Using Ant Colony Optimization Algorithm", *Asian Journal of Geoinformatics*; Vol. 10, No. 4, pp. 91-97, 2010.
- [10] Mosavi, M. R., "Applying Genetic Algorithm to Fast and Precise Selection of GPS Satellites", *Asian Journal of Applied Sciences*; Vol. 4, No. 3, pp. 229-237, 2011.
- [11] Ranjbar, M., Mosavi, M. R., "Simulated Annealing Clustering for Optimum GPS Satellite Selection", *IJCSI International Journal of Computer Science Issues*; Vol. 9, No. 3, pp. 100-104, 2012.
- [12] Jwo, D. J., Chin, K. P., "Applying Back-propagation Neural Networks to GDOP Approximation", *Journal of navigation*; Vol. 55, No. pp. 97-108, 2002.
- [13] Vapnik, V. N., Golowich, S. E., Smola, A. J., "Support vector machine for function approximation, regression estimation and signal procession", *Adv. Neural Information Procession Syst*; Vol. 9, No. 9, pp. 281-287, 1995.
- [14] Cao, L. J., Tay, F. E. H., "Support vector machine with adaptive parameters in financial time series forecasting", *IEEE Transactions on Neural Network*; Vol. 14, No. 6, pp. 1506-1518, 2003.
- [15] Farag, A., Refaat, M. M., *Regression Using Support Vector Machines: Basic Foundations. Technical Report. [Online]. Available: <http://wenku.baidu.com/view/256be2ef0975f46526d3e107.html>*
- [16] Minqiang, P., Dehuai, Z., Gang, X. u., "Temperature Prediction of Hydrogen producing reactor using SVM regression with PSO-SVM", *Journal of computers*; Vol. 5,

- [29] Shih-Wei, L., Kuo-Ching, Y., Shih-Chieh C., Zne-Jung, L., "Particle swarm optimization for parameter determination and feature selection of support vector machines", Expert Systems with Applications; Vol. 35, No. 4, pp. 1817-1824, 2008.
- [30] <http://www.u-blox.com/en/download/documents-a-resources/gps-solutions.html>

¹ - Geometric Dilution of Precision

² - Particle Swarm Optimization

³ - Support Vector Machine

⁴ - Genetic Algorithm