

روشی جدید برای بهبود کلاس‌بندی اهداف هوایی راداری

توسط کرنل‌های مختلف ماشین بردار پشتیبان

سید محمد علوی^{*}، مرتضی حاج‌محمدی^۲، محمد‌هادی رضایتی^۲

۱- استادیار ۲- کارشناسی ارشد دانشگاه جامع امام حسین (ع)

(دریافت: ۹۱/۰۹/۲۶، پذیرش: ۹۲/۱۰/۱۰)

چکیده

امروزه مبحث کلاس‌بندی اهداف هوایی اهمیت روزافزونی یافته است و روش‌های مختلفی برای رسیدن به این هدف مورد استفاده قرار می‌گیرد. ماشین بردار پشتیبان از جمله جدیدترین روش‌های مورد استفاده در این حوزه می‌باشد. در این مقاله برای کلاس‌بندی سه هدف جنگنده، هوایپیمای مسافربری و هلی کوپتر از سه روش کلاس‌بندی چند کلاسه ماشین بردار پشتیبان شامل روش یکی در برابر همه و گراف غیرچرخشی جهت‌دار پیشنهاد شده است و به دلیل اینکه کلاس‌ها به طور خطی به خوبی قابل تفکیک نبودند، از ایده توابع کرنل مثل چند جمله‌ای، خطی، مرتبه دوم و تابع پایه شعاعی استفاده شده است. با توجه به نتایج به دست آمده از شبیه‌سازی سه روش مذکور، روش گراف غیرچرخشی جهت‌دار با توابع کرنل مختلف دارای بهترین عملکرد است. همچنین روش یکی در برابر همه با کرنل RBF و مجذوری بهتر از روش یکی در برابر یکی با توابع کرنل مختلف عمل می‌کند. در این مقاله سرعت اجرای سه روش نیز مورد بررسی قرار گرفته است و نتایج به دست آمده نشان می‌دهد که سه روش دارای سرعت اجرای یکسانی می‌باشند. بنابراین به منظور کلاس‌بندی اهداف فوق، روش گراف غیرچرخشی جهت‌دار که دارای دقت بهتری می‌باشد، پیشنهاد شده است.

کلید واژه‌ها: ماشین بردار پشتیبان، روش گراف غیرچرخشی جهت‌دار، کلاس‌بندی چند کلاسه، توابع کرنل.

New Method to Improve Classification of Radar Object by Different Kernel of Support Vector Machine

S. M. Alavi^{*}, M. Hajmohammadi, M. H. Rezayati

Imam Hossein University

(Received: 16/12/2012; Accepted: 31/12/2013)

Abstract

Today, the importance of classification of radar object has drastically grown and numerous methods have been applied to achieve this goal. Support Vector Machine (SVM) stands among the newest methods on this subject. Herein, three different types of SVM methods have been suggested for fighter, airplane and helicopter including on-vs-one method, one-vs-rest method and directional acyclic graph method. Since these methods were not sufficiently capable of being distinctive in a linear way, some concepts of Kernel function such as polynomial, linear, quadratic and basic radial function have been used. Directional acyclic graph method using Kernel function yielded the best results according to the outputs obtained from simulation. One-vs-rest method using RBF and quadratic Kernel as well, was more adapted than on-vs-one method. The run time of performing these three methods is also deeply verified. The results showed a similar run time for all the three. Hence, to classify the noted goal, the method of directional acyclic graph is proposed as it manifests the most optimized performance in terms of accuracy.

Keywords: Support Vector Machine, Direct Non-Acyclic Graph, Multiclasses Classification Support Vector Machine, Kernel Function.

۱. مقدمه

جهت دار با توابع کرnel مختلف برای SVM نشان داده شده است. سپس با استفاده از دو نمودار میانگین مریعات خطأ و زمان کلاس بندی به ارزیابی و مقایسه روش های مورد بحث با یکدیگر پرداخته شده و نتایج حاصل ارائه شده است.

۲. ماشین بردار پشتیبان (SVM)

یک مسئله کلاس بندی معمولی را در نظر گرفته، برخی بردارهای ورودی و برخی گروههای کلاس بندی داده شده اند. هدف مسئله کلاس بندی، پیش بینی گروههای بردارهای ورودی جدید، به گونه ای که نسبت خطای کلاس بندی کمینه باشد، است.

الگوریتم های زیادی برای حل چنین نوعی از مسائل وجود دارد. برخی از این ها نیاز دارند که داده های ورودی به طور خطی از هم جدا شوند، اما برای تعداد زیادی از کاربردها این فرض مناسب نیست و حتی اگر این فرض در نظر گرفته شود، راه حل های ممکن زیادی برای حل این مسئله وجود دارد [۶].

و اپنیک [۱] و [۷] یک رویکرد ریاضی برای حل این نوع مسائل بهینه سازی معرفی کرد. اساس این روش این است که داده های آموزش در فضای با بعد کمتر به یک فضای ویژگی با بعد بالاتر نگاشت شوند، زیرا در این فضای ویژگی کلاس بندی داده های ورودی آسان تر است. علاوه بر این با استفاده از این روش این امکان وجود دارد که داده های آموزشی که به طور خطی نمی توانند از هم جدا شوند، در فضای ویژگی جدید به طور خطی از هم جدا شوند. این روش به وسیله استفاده از توابع کرnel به دست می آید.

شكل (۱) یک طبقه بندی کننده حاشیه بیشینه و بردارهای پشتیبان را نشان می دهد. ایده اصلی این روش ایجاد یک ابر صفحه به عنوان سطح تصمیم گیری است، به طوری که حد تفکیک بین نمونه های مثبت و منفی حداکثر شود. این روش با استفاده از یک شیوه که بر پایه آموزش آماری بنا نهاده شده، به خصیصه های بهینه فوق دست پیدا می کند. به صورت دقیق تر، ماشین بردار پشتیبان یک پیاده سازی تقریبی از روش حداقل کردن ریسک ساختاری است. این الگوریتم جزء الگوریتم های با نظارت است و در ابتدا نیاز به آموزش آمده دارد. این الگوریتم در حالت استاندارد برای مسائل تفکیک پذیر خطی طراحی شده و فقط قادر به تمیز دو کلاس است. در مرحله آموزش بردارهای ویژگی با یک ابر صفحه تفکیک می شوند و معادله این ابر صفحه به گونه ای محاسبه می شود که حد تفکیک (فاصله بین نزدیک ترین نقاط هر دسته با ابر صفحه) در آن بیشینه شود و ابر صفحه بهینه را به دست دهد، سپس بردارهایی از دو کلاس که کمترین فاصله را از ابر صفحه دارند، به عنوان کوچک ترین زیر مجموعه داده های آموزش که توسط الگوریتم فوق استخراج شده اند مشخص شده، و بردار پشتیبان نامیده می شوند و پس از این و در مرحله آزمایش فقط همین بردارها مورد استفاده قرار می گیرند. سپس در مرحله آزمایش بر اساس یک هسته ضرب داخلی بین یک بردار پشتیبان و یک بردار به دست آمده از فضای ورودی، دسته بردار ورودی مشخص می شود.

هدف های هوایی مختلفی وجود دارند از قبیل: هوایی های مسافربری، جنگنده ها، هلی کوپترها، پهباها و غیره هر یک از این اهداف مشخصه های متحصر به فردی دارند که می توان از آن ها برای شناسایی استفاده کرد، از جمله این مشخصه ها می توان به سطح مقطع راداری و سرعت اشاره کرد. با استفاده از رادارها می توان این مشخصه ها را برای اهداف به دست آورد. سطح مقطع راداری برای یک هوایی های تک موتوره در حدود یک متر مربع، هلی کوپترها در حدود ۳ متر مربع است. همچنین سرعت هوایی های جنگنده به مراتب بیشتر از سرعت هوایی های مسافربری و هلی کوپترها است. برای کلاس بندی اهداف روش های متعددی مورد استفاده قرار گرفته است، که می توان به روش های مبتنی بر شبکه های عصبی، ماشین های بردار پشتیبان و روش های آماری اشاره کرد. اولین الگوریتم برای طبقه بندی و دسته بندی الگوها در سال ۱۹۳۶ توسط Fisher ارائه شد و معیار آن برای بهینه بودن، کم کردن خطای طبقه بندی الگوهای آموزشی بود. بسیاری از الگوریتم ها و روش های نیز که تاکنون برای طراحی طبقه بندی کننده ها گلو ارائه شده است، از همین راهبرد پیروی می کنند. در هیچ یک از این روش ها خاصیت تعمیم طبقه بندی کننده به طور مستقیم درتابع هزینه روش دلالت داده نشده است و طبقه بندی کننده طراحی شده نیز دارای خاصیت تعمیم دهنده کی است. محقق روسی به نام و اپنیک [۱] گامی بسیار مهم در طراحی دسته بندی کننده ها برداشت و نظریه یادگیری آماری را به صورت مستحکم تری بنا نهاد و ماشین های بردار پشتیبان را بر این اساس ارائه داد. ماشین بردار پشتیبان یکی از پویا ترین و جدید ترین حوزه های تحقیق در حال حاضر است که محققین زیادی را در زمینه های گوناگون علمی به خود جلب کرده است. ماشین های بردار پشتیبان (SVM)، کلاسی از الگوریتم های یادگیری هستند که بر اساس اصول کمینه سازی ریسک عملیاتی بنا شده اند [۲]. ماشین های بردار پشتیبان در تعداد زیادی از زمینه های یادگیری ماشین، از جمله کلاس بندی، تخمین رگرسیون و غیره استفاده می شوند. در مقاله های زیادی از این روش به عنوان کلاس بندی استفاده شده است. در کاربردهای راداری، بارکر [۳] یک رویکرد دو مرحله ای به کمک ماشین بردار پشتیبان برای شناسایی اهداف راداری پالس داپلر ارائه داده است. مایکل اندرسون [۴] به موضوع کلاس بندی بر اساس تفاوت های آماری به کمک ماشین بردار پشتیبان پرداخته و از آن در طراحی یک رادار چند فرکانسی موج پیوسته بر اساس آشکارسازی و کلاس بندی بهره گرفته است.

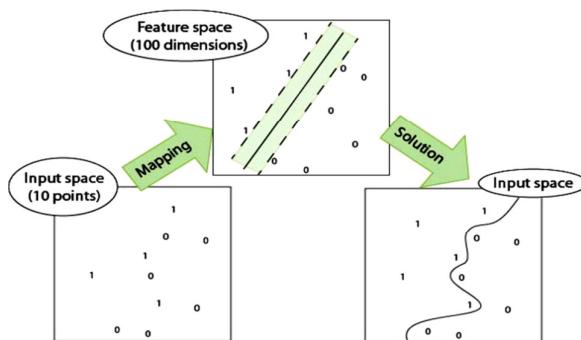
در این مقاله، مفاهیم اولیه شامل ماشین بردار پشتیبان، توابع کرnel، کلاس بندی چند کلاسه و مدل تولید داده های آزمون آمده است و نتایج شبیه سازی برای کلاس بندی به سه روش مورد نظر شامل یکی در برابر یکی، یکی در برابر همه و گراف غیر چرخشی

بالاتر استفاده می‌شود. می‌توان از یک تابع $k(x_i, x_j)$ که ضرب نقطه‌ای را در فضای ویژگی محاسبه می‌کند، به عنوان یک عملیات مستقیم بر روی نمونه داده‌های اصلی استفاده کرد [۹].

$$k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (6)$$

تابع k یک کرنل نامیده شده و SVM‌ها یک عضو از کلاس گسترده از روش‌های کرنل هستند [۱۰].

شکل (۲) عملکرد یک تابع کرنل در نگاشت داده‌های ورودی به یک فضای ویژگی و انجام عملیات کلاس‌بندی را نشان می‌دهد.



شکل ۲. نمایش نقش کرنل در یک مسئله کلاس‌بندی [۱۲]

توابع کرنل به جای ضرب نقطه‌ای بردارهای تبدیل یافته، جایگزین می‌شوند و شکل واضح و روش تابع تبدیل ϕ لزوماً شناخته شده نیست. به علاوه استفاده از تابع کرنل به شدت به محاسبات کمتری نیاز دارد.

مسئله بهینه‌سازی به صورت زیر در می‌آید [۷]:

$$\max(\sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k k(x_i, x_j) \alpha_i \alpha_j y_i y_j) \quad (7)$$

$$s.t. \quad \sum_{i=1}^k \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq c, i = 1, 2, \dots, n \quad (8)$$

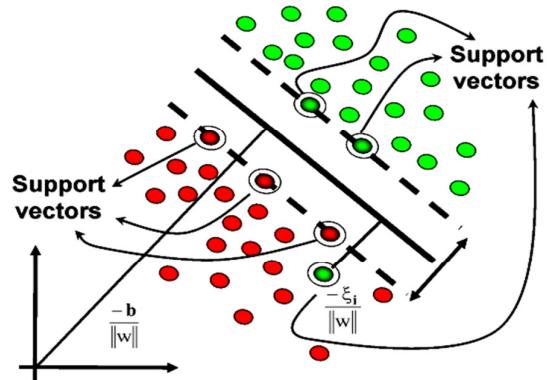
بر اساس تابع تصمیم‌گیری به صورت زیر است:

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i^* y_i K(x, x_i) + b^*) \quad (9)$$

توابع کرنل مرسوم در جدول (۱) لیست شده است.

۴. مدل تولید مصنوعی داده‌های آزمون

مدل مخلوطی گوسی روشی است که به وسیله آن می‌توان داده‌هایی با توزیع گوسی با میانگین و واریانس مورد نظر تولید کرد و برای مسائل کلاس‌بندی از آن‌ها بهره جست. در این مقاله برای تولید داده‌های آزمون از روی داده‌های آموزشی، از این مدل استفاده شده است. برای این منظور ابتدا میانگین و واریانس سه کلاس داده‌های



شکل ۱. حاشیه بیشینه و بردارهای پشتیبان [۸]

مسئله بهینه‌سازی ماشین بردار پشتیبان به صورت زیر است [۷]:

$$\min\left(\frac{1}{2}\|w\|^2\right) \quad (1)$$

$$s.t. \quad y_i(X_i^T W + b) - 1 \geq 0, \quad 1 \leq i \leq n$$

با استفاده از ضرایب لاغرانژ که در [۷] به آن اشاره شده است، مسئله بهینه‌سازی به صورت زیر تبدیل می‌شود:

$$\begin{aligned} \max(w(\alpha)) &= \sum_{i=1}^n \alpha_i - (\sum_{ij} \alpha_i \alpha_j y_i y_j (x_i x_j)) / 2 \\ s.t. \quad \sum_{i=1}^n \alpha_i y_i &= 0 \\ 0 \leq \alpha_i &\leq c, i = 1, 2, \dots, n \end{aligned} \quad (2)$$

تابع f که می‌تواند برای کلاس‌بندی داده‌های آزمون جدید استفاده شود به صورت زیراست:

$$f(x) = w^T x - b^* = \sum_i \alpha_i y_i x_i^T x - b^* \quad (3)$$

$$b^* = (\sum_i \alpha_i y_i x_i^T x - y_i) \quad (4)$$

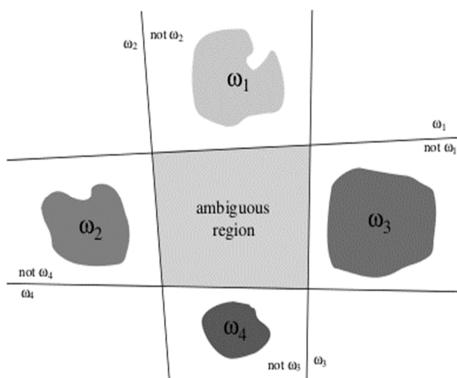
در فرمول (۴)، i یک ماشین بردار پشتیبان است. در نهایت تابع تصمیم‌گیری ابرصفحه می‌تواند به صورت زیر نوشته شود [۸]:

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i^* y_i (x x_i) - b^*) \quad (5)$$

۳. توابع کرنل

تاکنون فقط تابع تصمیم‌گیری خطی مورد توجه قرار گرفت. ایده کلیدی ماشین بردار پشتیبان، انتقال فضای ورودی به یک فضای ویژگی با ابعاد بالاتر است، که داده‌های آموزشی در آن به صورت خطی قابل جذاسازی هستند. تابع تصمیم‌گیر خطی در فضای ویژگی، عموماً در فضای ورودی غیرخطی است. برای مسائلی که یک ابرصفحه تصمیم‌گیری غیرخطی لازم است، یک تابع نگاشت $\phi(x)$ برای انتقال داده‌های اصلی به یک فضای ویژگی با ابعاد

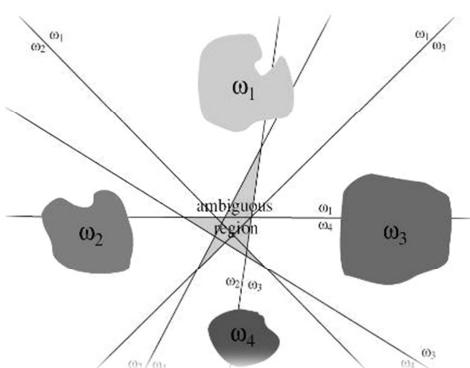
K. تعداد نتایج کلاس بندی کننده دوتایی $K(K-1)/2$ است و هر کلاس در ۱ K-1 مدل استفاده می شود [۱۲].



شکل ۳. روش کلاس بندی یکی در برابر همه برای حالت کلاسه ۴

۲-۵. روش یکی در برابر یکی (OVO)

قدیمی ترین روش کلاس بندی چند کلاسه ماشین بردار پشتیبان احتمالاً روش یکی در برابر یکی است [۱۱]. در این روش برای کلاس بندی K کلاسه، K کلاس بندی کننده دوتایی ماشین بردار پشتیبان در نظر گرفته شده است. هر کلاس بندی کننده برای تمیز کردن یک کلاس از دیگر کلاس های باقی مانده آموزش داده می شود [۸].



شکل ۴. روش کلاس بندی یکی در برابر یکی برای حالت کلاسه ۴

۳-۵. روش گراف غیر چرخشی جهت دار (DAG)

گراف غیر چرخشی جهت دار بر پایه گراف غیر چرخشی مستقیم ماشین بردار پشتیبان استوار است. این روش یکی از روش های کلاس بندی چند کلاسه است که توسط پلات [۱۳] و [۱۱] ارائه شده است و در آن فاز آموزش دقیقاً مشابه با روش یکی در برابر یکی اعمال می شود، بنابراین این روش از $K(K-1)/2$ کلاس بندی کننده دوتایی استفاده می کند با این تفاوت که این روش خود را در فاز کلاس بندی به وسیله یک ساختار درختی دوتایی دوتایی ریشه ای با گره درختی گرفته و سایز C را شامل یک کلاس بندی کننده دوتایی از نمین و زمین کلاس است.

آموزشی استخراج شده و سپس تعداد ۳۰۰ داده آزمون برای آزمایش به این روش تولید می شود. مدل مخلوطی کلی را می توان به صورت رابطه (۱۰) نشان داد [۱۲].

جدول ۱. توابع کرنل متدائل [۸] و [۱۱]

Kernel Function	Definition	Parameters
Linear	$x \cdot x_i$	-
Quadratic	$\tanh(\lambda x \cdot x_i + r)$	r, λ, σ
Polynomial	$(\lambda x \cdot x_i + r)^d$	r, λ, d
RBF ^۱	$\exp\left(-\frac{\lambda \ x - x_i\ ^2}{2\sigma^2}\right)$	λ, σ

$$F_k(x) = \sum_{k=1}^K c_k f_k(x) \quad (10)$$

که در آن، $c_k \geq 0$ و $\sum_{k=1}^K c_k = 1$ است. K تعداد مؤلفه های مخلوطی، x یک بردار داده ورودی، c_k ضریب وزن، $f_k(x)$ نمایانگر تابع توزیع K امین مؤلفه مخلوطی و (x) تابع توزیع نهایی ناشی از K توزیع مخلوطی است. نوع مدل مخلوطی به وسیله نوع تابع توزیع تعیین می شود و بنابراین مدل مخلوطی گوسی بر اساس تابع توزیع گوسی شناخته می شود.

$$f_k(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-(x - \mu)^2 / 2\sigma^2\right) \quad (11)$$

که پارامتر σ^2 واریانس و μ مقدار میانگین (یا موقعیت پیک) یک مؤلفه مخلوطی است. در شبیه سازی انجام شده، از یک توزیع گوسی برای تولید داده های آزمون استفاده شده و بنابراین $c_k = K=1$ در نظر گرفته شده است.

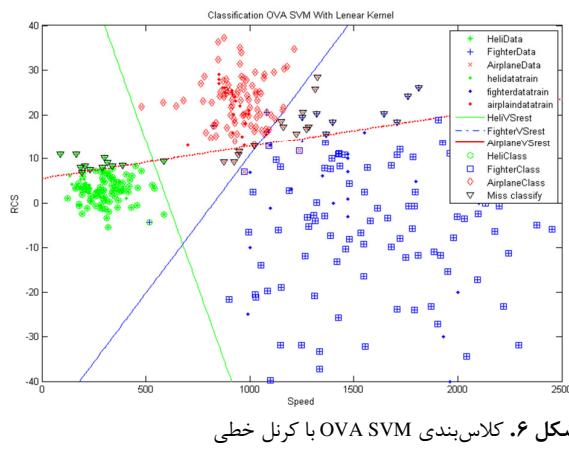
۵. روش های کلاس بندی چند کلاسه

روش SVM یک دسته بندی کننده دوتایی است. در مورد مسائل چند کلاسی رهیافت کلی، کاهش مسئله چند کلاسی به چندین مسئله دوتایی است. سپس خروجی های دسته بندی کننده های دوتایی با هم ترکیب شده و به این ترتیب مسئله چند کلاسی حل می شود. برای کلاس بندی چند کلاسه SVM، سه روش وجود دارد که عبارت هستند از: روش یکی در برابر همه، روش یکی در برابر یکی و روش گراف درختی جهت دار.

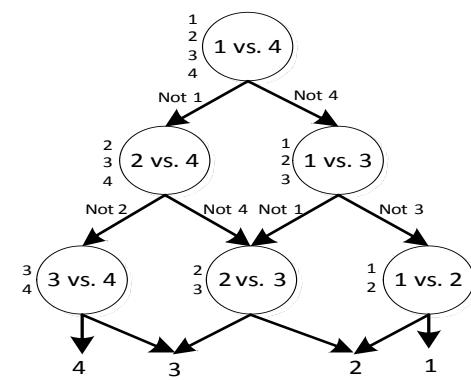
۵-۱. روش یکی در برابر همه (OVA)

این روش کلاس بندی به وسیله فریدمن [۱۰] پیشنهاد شد که یکی از مرسم ترین و موفق ترین روش های چند کلاسه ماشین بردار پشتیبان است. در این روش یک ماشین بردار پشتیبان دوتایی، برای هر یک از ترکیب کلاس های ممکن ساخته می شود. برای توصیف کلاس بندی کننده به شکل دیگر، مجموعه کلاس ها را C در نظر گرفته و سایز C را

^۱ Radial Basis Function

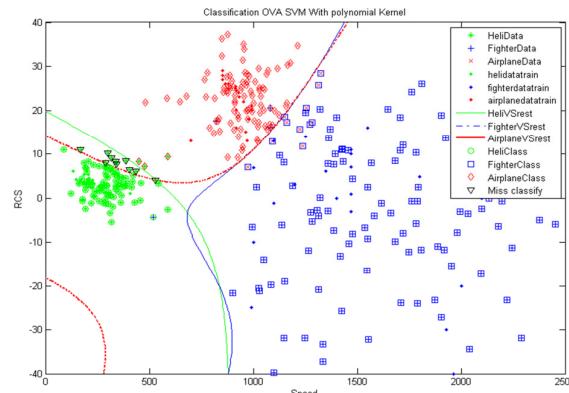


شکل ۶. کلاس‌بندی OVA SVM با کرnel خطی

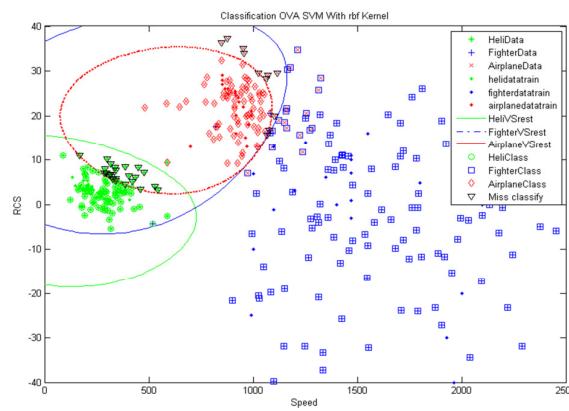


شکل ۵. روش گراف غیرچرخشی جهت‌دار برای حالت

[۱۲] ۴ کلاسه



شکل ۷. کلاس‌بندی OVA SVM با کرnel چند جمله‌ای



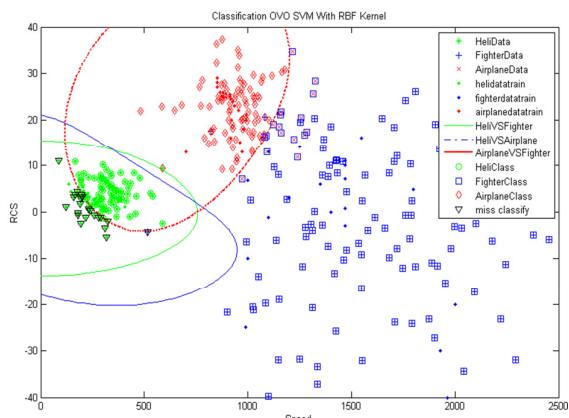
شکل ۸. کلاس‌بندی OVA SVM با کرnel rbf

به همین ترتیب شکل‌های (۱۰ - ۱۳) به ترتیب کلاس‌بندی OVO را برای کرnel‌های خطی، تابع پایه شعاعی، چند جمله‌ای و درجه دوم را نشان می‌دهد. شکل‌های (۱۴ - ۱۷) نیز به ترتیب کلاس‌بندی DAG را برای کرnel‌های خطی، تابع پایه شعاعی، چند جمله‌ای و درجه دوم را نشان می‌دهد.

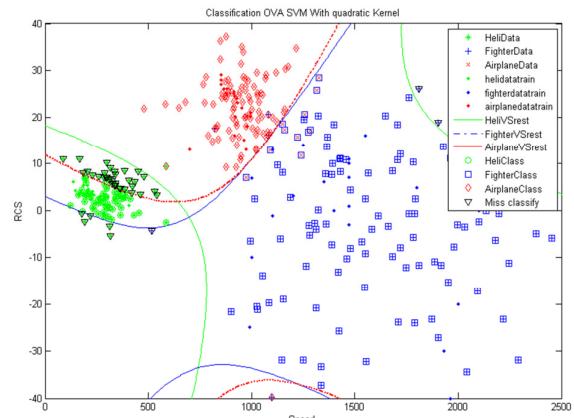
۶. شبیه‌سازی

ابتدا از ۶۰ داده آموزشی که متتشکل از ۲۰ داده هوایی مسافربری، ۲۰ داده هوایی جنگنده و ۲۰ داده هلیکوپتر است، برای آموزش شبکه‌ها استفاده می‌شود. با استفاده از مدل مخوطی گوسی ۳۰۰ داده آزمون متتشکل از ۱۰۰ داده هوایی مسافربری، ۱۰۰ داده هوایی جنگنده و ۱۰۰ داده هلیکوپتر ایجاد شده است. داده‌ها با استفاده از دو ویژگی سرعت و سطح مقطع راداری تصویف شده‌اند. در این مقاله با توجه به اینکه داده‌ها به صورت خطی به خوبی قابل تفکیک نیستند، برای دست‌یابی به کلاس‌بندی مطلوب از توابع کرnel در SVM استفاده شده است. بر این اساس عملکرد توابع کرnel برای هر کدام از روش‌های کلاس‌بندی چند جمله‌ای SVM مورد ارزیابی قرار خواهد گرفت.

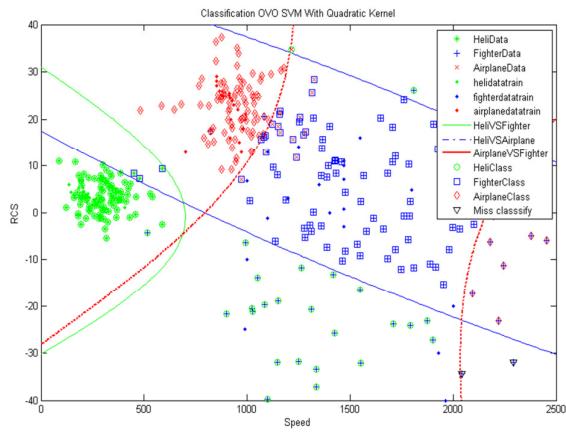
همان‌طور که در شکل‌های زیر مشخص است، داده‌های هلیکوپتر با رنگ سبز، داده‌های جنگنده با رنگ آبی و داده‌های مسافربری با رنگ قرمز مشخص شده‌اند. ابتدا با ۶۰ داده آموزشی، شبکه ماشین بردار پشتیبان را آموزش داده، سپس با استفاده از بردارهای پشتیبان مشخص شده، داده‌های آزمون کلاس‌بندی می‌شوند. در این مقاله از سه روش ذکر شده برای کلاس‌بندی اهداف استفاده می‌شود. شکل (۶) کلاس‌بندی OVA با کرnel خطی را نشان می‌دهد همان‌طور که از شکل مشخص است، کلاس‌ها به خوبی از هم تفکیک نشده‌اند. شکل (۷) کلاس‌بندی OVA با کرnel چند جمله‌ای را نشان می‌دهد که این روش دقت بیشتری نسبت به کرnel خطی دارد. شکل (۸) کلاس‌بندی OVA با کرnel تابع پایه شعاعی را نشان می‌دهد، که این روش از دقت بالایی برخوردار است. در نهایت شکل (۹) کلاس‌بندی OVA با کرnel درجه دوم را نشان می‌دهد، که این روش از دقت خوبی برخوردار است.



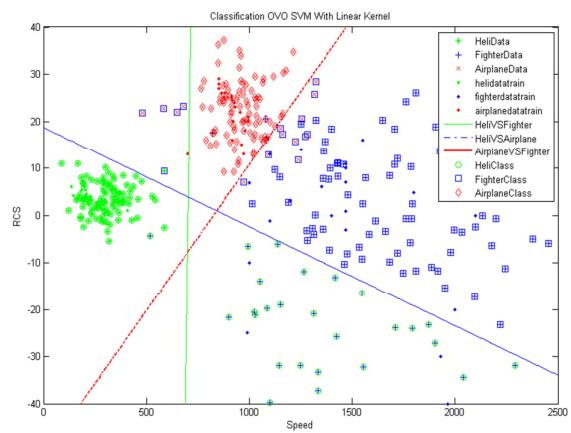
شکل ۱۲. کلاس‌بندی OVO SVM با کرنل rbf



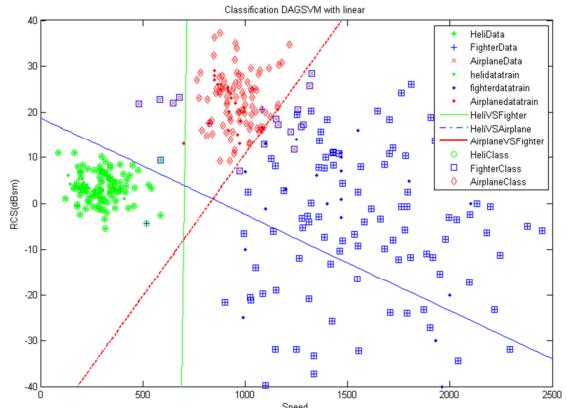
شکل ۹. کلاس‌بندی OVA SVM با کرنل quadratic



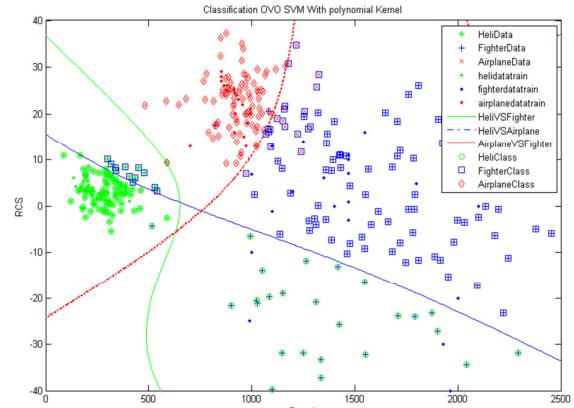
شکل ۱۳. کلاس‌بندی OVO SVM با کرنل quadratic



شکل ۱۰. کلاس‌بندی OVO SVM با کرنل خطی



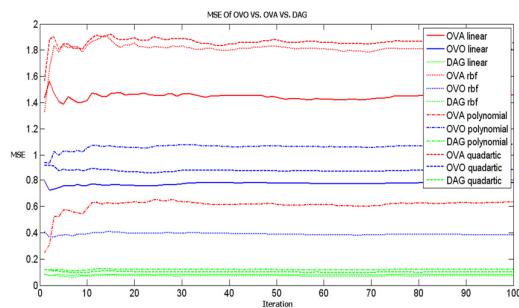
شکل ۱۴. کلاس‌بندی DAG SVM با کرنل خطی



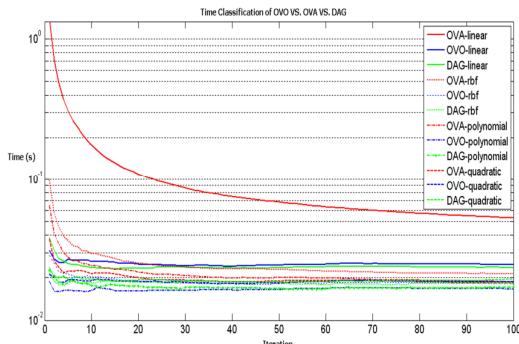
شکل ۱۱. کلاس‌بندی OVO SVM با کرنل چند جمله‌ای

کلاس‌بندی با استفاده از کرنل تابع پایه شعاعی عملکرد بهتری دارد. در روش DAG هر ۴ کرنل مختلف دارای دقت یکسانی در کلاس‌بندی هستند. همان‌طور که از شکل (۱۹) مشخص است سرعت اجرای همه تقریباً نزدیک به هم است و توجه داشته باشید که در اینجا چون مسئله کلاس‌بندی ما سه کلاسه است، تعداد اجرای کلاس‌بندی دوتایی برای روش یکی در برابر یکی و یکی در برابر همه، سه بار است، ولی اگر مسئله کلاس‌بندی به کلاس‌های بیشتری تبدیل شود، بر اساس روابط گفته شده روش یکی در برابر همه وضعیت بهتری از دو

به منظور ارزیابی، دقت کلاس‌بندی سه روش با کرنل‌های مختلف و سرعت اجرای الگوریتم‌های هر روش محاسبه می‌شود. برای ارزیابی دقت کلاس‌بندی، الگوریتم‌های کلاس‌بندی برای ۱۰۰۰ تکرار مختلف با داده‌های آزمون متفاوت اجرا شده‌اند و میانگین مربعات خطای هر روش در هر اجرا به دست آمده است. نتایج این ارزیابی در شکل (۱۸) آمده است. در روش یکی برابر همه کلاس‌بندی با استفاده از کرنل چند جمله‌ای نسبت به دیگر کرنل‌ها دقت بیشتری دارد، اما کرنل خطی دارای دقت بسیار پایینی است. در روش یکی در برابر یکی



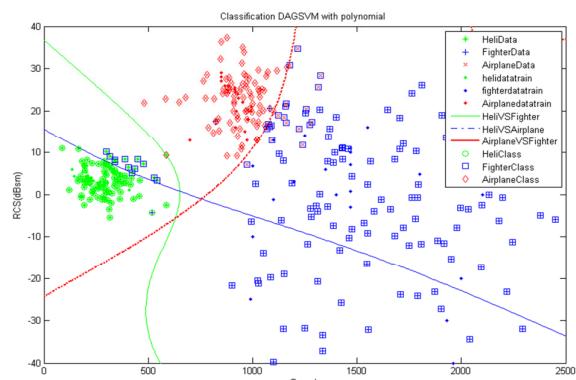
شکل ۱۸. مقایسه میانگین مربعات خطأ برای کرنل‌های مختلف



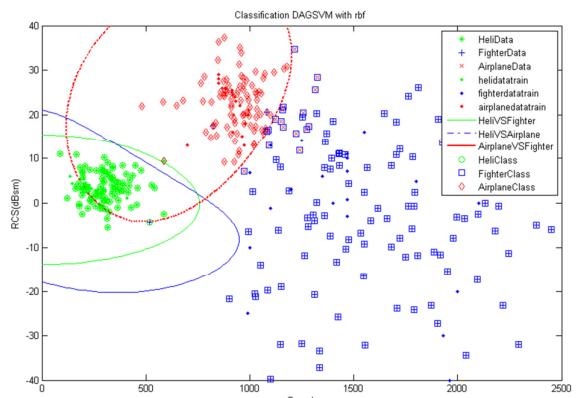
شکل ۱۹. مقایسه زمان اجرا برای کرنل‌های مختلف

روش دیگر خواهد داشت. از نمودار شکل (۱۸) می‌توان فهمید که روش DAG دارای دقت بسیار بالایی نسبت به دو روش دیگر است. همچنین روش یکی در برابر همه نسبت به روش بکی در برابر یکی از دقت بالاتری برخوردار است.

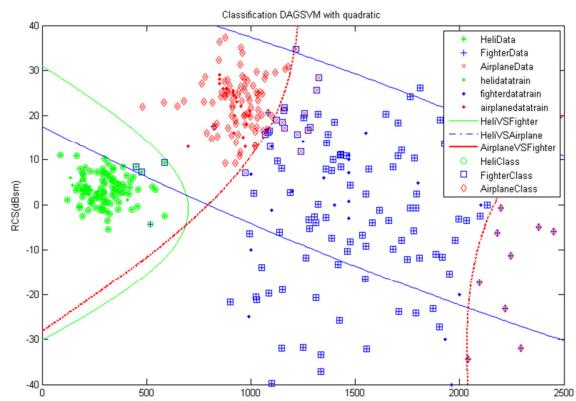
برای حالتهای که کلاس‌ها به طور خطی به خوبی قابل تفکیک نیستند، استفاده از توابع کرنل خطی عملکرد بسیار پایینی دارد و می‌باشد از توابع کرنل غیر خطی استفاده کرد.



شکل ۱۵. کلاس‌بندی DAG SVM با کرنل چند جمله‌ای



شکل ۱۶. کلاس‌بندی DAG SVM با کرنل rbf



شکل ۱۷. کلاس‌بندی DAG SVM با کرنل quadratic

۷. نتیجه‌گیری

کلاس‌بندی اهداف یکی از موضوعات مهم در سامانه‌های رادار است. روش‌های مختلفی برای کلاس‌بندی استفاده می‌شود که از مهم‌ترین روش‌های ارائه شده در این زمینه روش ماشین بردار پشتیبان است. اساساً روش SVM برای کلاس‌بندی دوتایی طراحی شده است، اما با استفاده از تکنیک‌هایی از آن نیز برای کلاس‌بندی چند کلاسه استفاده می‌شود. در این مقاله روش SVM برای کلاس‌بندی اهداف هوایی مورد بررسی قرار گرفتند. در میان روش‌های کلاس‌بندی چند کلاسه SVM، از روش‌های یکی در برابر همه، یکی در برابر بکی و گراف غیرچرخشی جهت‌دار در این مقاله بهره گرفته شد. از معیار میانگین مربعات خطأ برای بررسی دقت کلاس‌بندی استفاده شد. در موقعی که کلاس‌ها به صورت خطی به خوبی قابل تفکیک نیستند، می‌باشد از توابع کرنل غیر خطی استفاده کرد. با توجه به نتایج به دست آمده در این سه روش مذکور، روش گراف غیرچرخشی جهت‌دار با توابع کرنل مختلف دارای بهترین عملکرد است. به همین ترتیب روش یکی در برابر همه با کرنل RBF و مجذوری^۱ بهتر از روش یکی در برابر یکی با توابع کرنل مختلف عمل می‌کند. در این مقاله سرعت اجرای سه روش نیز مورد بررسی قرار گرفت، که نتایج به دست آمده نشان می‌دهد که سه روش دارای سرعت اجرای یکسانی می‌باشند.

^۱Quadratic

- [7] Watanach, P. M.; Arora, K.; Varshney, P. K. "Evaluation of Factors Affecting Support Vector Machines for Hyperspectral Classification"; in Proc. American Soc. Photogrammetry & Remote Sensing (ASPRS-2004) Annual Conf. 2004, 23-28.
- [8] Platt N. C. J.; Shawe-Taylor, J. "Large Margin DAGs for Multiclass Classification"; Technical Report, Microsoft Research, Redmond, US, 1999.
- [9] Aiolfi, F.; Sperduti, A. "Multiclass Classification with Multi-Prototype Support Vector Machines"; J. Machine Learning Research 2005, 6, 817-850.
- [10] Balada, R. "Radar Signal Recognition Method Based on Gaussian Mixture Models"; Doctoral Degree Program.
- [11] Krebel, U. "Pairwise Classification and Support Vector Machine"; in B. Schölkopf, C. J. C. Burges, and A. J. Smola, Editors, Advances in Kernel Methods- Support Vector Learning, Cambridge, MIT Press.; MA,1999, 255-268.
- [12] Solomon, J. "Support Vector Machines for Phoneme Classification"; Master of Sci., Schools of Artificial Intelligence Division of Informatics Univ. of Edinburg, Page 34, 2001.
- [13] Chang, Q.; Chen, Q.; Wang, X. "Scaling Gaussian RBF Kernel Width to Improve SVM Classification"; IEEE International Conference on Neural Networks and Brain, IC- NNB'05; Oct 2005, pp 20.

۸. مراجع

- [1] Vapnik, V. "Pattern Recognition Using Generalized Portrait Method"; Automation and Remote Control 1963, 24, 774-780.
- [2] Burges, C. J. "A Tutorial On Support Vector Machines For Pattern Recognition"; Data Mining and Knowledge Discovery 2.2, 1998, 121-167.
- [3] Baker, C. "Pulse Doppler Radar Target Recognition Using a Two-Stage SVM procedure"; IEEE Trans. on Aerospace and Electronic Sys. 2011, 47, 1450-1457.
- [4] Anderson, M. G. "Design of Multiple Frequency Continuous Wave Radar Hardware and Micro-Doppler Based Detection and Classification Algorithms"; Ph.D Thesis, Faculty of the Graduate School of the Univ. of Texas at Austin, May 2008.
- [5] Friedman, J. H. "Another Approach to Polychotomous Classification"; Technical Report, Stanford Department of Statistics, 1996.
- [6] Hsu, C. W.; Lin, C. J. "A Comparison Methods for Multiclass Support Vector Machines"; IEEE Trans. on Neural Networks 2002, 13, 415-425.