

روشی جدید برای بهبود کلاس بندی اهداف هوایی راداری توسط کرنل های مختلف ماشین بردار پشتیبان

سید محمد علوی^{۱*}، مرتضی حاج محمدی^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 کلاس بندی اهداف هوایی اهمیت روزافزونی یافته است و روش های مختلفی برای رسیدن به این هدف مورد استفاده قرار می گیرد. ماشین بردار پشتیبان از جمله جدیدترین روش های مورد استفاده در این حوزه می باشد. در این مقاله برای کلاس بندی سه هدف جنگنده، هواپیمای مسافربری و هلی کوپتر از سه روش کلاس بندی چند کلاسه ماشین بردار پشتیبان شامل روش یکی در برابر یکی، یکی در برابر همه و گراف غیر چرخشی جهت دار پیشنهاد شده است و به دلیل اینکه کلاس ها به طور خطی به خوبی قابل تفکیک نبودند، از ایده توابع کرنل مثل چند جمله ای، خطی، مرتبه دوم و تابع پایه شعاعی استفاده شده است. با توجه به نتایج به دست آمده از شبیه سازی سه روش مذکور، روش گراف غیر چرخشی جهت دار 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 می کند. در این مقاله سرعت اجرای سه روش نیز مورد بررسی قرار گرفته است و نتایج به دست آمده نشان می دهد که سه روش دارای سرعت اجرای یکسانی می باشند. بنابراین به منظور کلاس بندی اهداف فوق، روش گراف غیر چرخشی جهت دار که دارای دقت بهتری می باشد، پیشنهاد شده است.

کلید واژه ها: ماشین بردار پشتیبان، روش گراف غیر چرخشی جهت دار، کلاس بندی 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, Multiclass Classification Support Vector Machine, Kernel Function.

* Corresponding Author E-mail: malavi@ihu.ac.ir

۱. مقدمه

هدف‌های هوایی مختلفی وجود دارند از قبیل: هواپیماهای مسافربری، جنگنده‌ها، هلی‌کوپترها، پهبادها و غیره هر یک از این اهداف مشخصه‌های منحصر به فردی دارند که می‌توان از آن‌ها برای شناسایی استفاده کرد، از جمله این مشخصه‌ها می‌توان به سطح مقطع راداری و سرعت اشاره کرد. با استفاده از رادارها می‌توان این مشخصه‌ها را برای اهداف به دست آورد. سطح مقطع راداری برای یک هواپیمای تک موتوره در حدود یک مترمربع، هلی‌کوپترها در حدود ۳ مترمربع است. همچنین سرعت هواپیماهای جنگنده به مراتب بیشتر از سرعت هواپیماهای مسافربری و هلی‌کوپترها است. برای کلاس‌بندی اهداف روش‌های متعددی مورد استفاده قرار گرفته است، که می‌توان به روش‌های مبتنی بر شبکه‌های عصبی، ماشین‌های بردار پشتیبان و روش‌های آماری اشاره کرد. اولین الگوریتم برای طبقه‌بندی و دسته‌بندی الگوها در سال ۱۹۳۶ توسط Fisher ارائه شد و معیار آن برای بهینه بودن، کم کردن خطای طبقه‌بندی الگوهای آموزشی بود. بسیاری از الگوریتم‌ها و روش‌هایی نیز که تاکنون برای طراحی طبقه‌بندی کننده‌ها الگو ارائه شده است، از همین راه‌برد پیروی می‌کنند. در هیچ‌یک از این روش‌ها خاصیت تعمیم طبقه‌بندی کننده به طور مستقیم در تابع هزینه روش دخالت داده نشده است و طبقه‌بندی کننده طراحی شده نیز دارای خاصیت تعمیم دهنده کمی است. محقق روسی به نام واپنیک [۱] گامی بسیار مهم در طراحی دسته‌بندی کننده‌ها برداشت و نظریه یادگیری آماری را به صورت مستحکم‌تری بنا نهاد و ماشین‌های بردار پشتیبان را بر این اساس ارائه داد. ماشین بردار پشتیبان یکی از پویاترین و جدیدترین حوزه‌های تحقیق در حال حاضر است که محققین زیادی را در زمینه‌های گوناگون علمی به خود جلب کرده است. ماشین‌های بردار پشتیبان (SVM¹)، کلاسی از الگوریتم‌های یادگیری هستند که بر اساس اصول کمینه‌سازی ریسک عملیاتی بنا شده‌اند [۲]. ماشین‌های بردار پشتیبان در تعداد زیادی از زمینه‌های یادگیری ماشین، از جمله کلاس‌بندی، تخمین رگرسیون و غیره استفاده می‌شوند. در مقاله‌های زیادی از این روش به عنوان کلاس‌بندی استفاده شده است. در کاربردهای راداری، بارکر [۳] یک رویکرد دو مرحله‌ای به کمک ماشین بردار پشتیبان برای شناسایی اهداف راداری پالس-دابلر ارائه داده است. مایکل اندرسون [۴] به موضوع کلاس‌بندی بر اساس تفاوت‌های آماری به کمک ماشین بردار پشتیبان پرداخته و از آن در طراحی یک رادار چند فرکانسی موج پیوسته بر اساس آشکارسازی و کلاس‌بندی بهره گرفته است.

در این مقاله، مفاهیم اولیه شامل ماشین بردار پشتیبان، توابع کرنل، کلاس‌بندی چند کلاسه و مدل تولید داده‌های آزمون آمده است و نتایج شبیه‌سازی برای کلاس‌بندی به سه روش مورد نظر شامل یکی در برابر یکی، یکی در برابر همه و گراف غیرچرخشی

جهت‌دار با توابع کرنل مختلف برای SVM نشان داده شده است. سپس با استفاده از دو نمودار میانگین مربعات خطا و زمان کلاس‌بندی به ارزیابی و مقایسه روش‌های مورد بحث با یکدیگر پرداخته شده و نتایج حاصل ارائه شده است.

۲. ماشین بردار پشتیبان (SVM)

یک مسئله کلاس‌بندی معمولی را در نظر گرفته، برخی بردارهای ورودی و برخی گروه‌های کلاس‌بندی داده‌شده‌اند. هدف مسئله کلاس‌بندی، پیش‌بینی گروه‌های بردارهای ورودی جدید، به گونه‌ای که نسبت خطای کلاس‌بندی کمینه باشد، است.

الگوریتم‌های زیادی برای حل چنین نوعی از مسائل وجود دارد. برخی از این‌ها نیاز دارند که داده‌های 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، راه‌حل‌های ممکن زیادی برای حل این مسئله وجود دارد [۶].

واپنیک [۱ و ۷] یک رویکرد ریاضی برای حل این نوع مسائل بهینه‌سازی معرفی کرد. اساس این روش این است که داده‌های آموزش در فضای با بعد کمتر به یک فضای ویژگی با بعد بالاتر نگاشت شوند، زیرا در این فضای ویژگی کلاس‌بندی داده‌های ورودی آسان‌تر است. علاوه بر این با استفاده از این روش این امکان وجود دارد که داده‌های آموزشی که به طور خطی نمی‌توانند از هم جدا شوند، در فضای ویژگی جدید به طور خطی از هم جدا شوند. این روش به وسیله استفاده از توابع کرنل به دست می‌آید.

شکل (۱) یک طبقه‌بندی کننده حاشیه بیشینه و بردارهای پشتیبان را نشان می‌دهد. ایده اصلی این روش ایجاد یک ابر صفحه به عنوان سطح تصمیم‌گیری است، به طوری که حد تفکیک بین نمونه‌های مثبت و منفی حداکثر شود. این روش با استفاده از یک شیوه که بر پایه آموزش آماری بنا نهاده شده، به خصیصه‌های بهینه فوق دست پیدا می‌کند. به صورت دقیق‌تر، ماشین بردار پشتیبان یک پیاده‌سازی تقریبی از روش حداقل کردن ریسک ساختاری است. این الگوریتم جزء الگوریتم‌های با نظارت است و در ابتدا نیاز به آموزش آماده دارد. این الگوریتم در حالت استاندارد برای مسائل تفکیک‌پذیر خطی طراحی شده و فقط قادر به تمیز دو کلاس است. در مرحله آموزش بردارهای ویژگی با یک ابر صفحه تفکیک می‌شوند و معادله این ابر صفحه به گونه‌ای محاسبه می‌شود که حد تفکیک (فاصله بین نزدیک‌ترین 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 کوچک‌ترین زیر مجموعه داده‌های آموزش که توسط الگوریتم فوق استخراج شده‌اند مشخص شده، و بردار پشتیبان نامیده می‌شوند و پس از این و در مرحله آزمایش فقط همین بردارها مورد استفاده قرار می‌گیرند. 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 می‌شود.


¹ Support Vector Machine

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 SVM ها یک عضو از کلاس گسترده از روش‌های کرنل هستند [۱۰].

شکل (۲) عملکرد یک تابع کرنل در نگاهت 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 روشن 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]:

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

$$s.t. \sum_{i=1}^k \alpha_i y_i = 0 \quad (8)$$

$$0 \leq \alpha_i \leq c, i = 1, 2, \dots, k$$


بر اساس تابع تصمیم‌گیری به صورت زیر است:

$$f(x) = \text{sign} \left(\sum_{\text{support Vector}} \alpha_i^o y_i K(x, x_i) + b^o \right) \quad (9)$$

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]:

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

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

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

$$\max (w(\alpha) = \sum_{i=1}^n \alpha_i - (\sum_{ij} \alpha_i \alpha_j y_i y_j (x_i x_j)) / 2) \quad (2)$$

$$s.t. \sum_{i=1}^n \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq c, i = 1, 2, \dots, n$$

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

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

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


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

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

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 جداسازی هستند. تابع تصمیم‌گیر خطی در فضای ویژگی، عموماً در فضای ورودی غیرخطی است. برای مسائلی که یک ابرصفحه تصمیم‌گیری غیر خطی لازم است، یک تابع نگاهت $\phi(x)$ برای انتقال داده‌های اصلی به یک فضای ویژگی با ابعاد


K، تعداد نتایج کلاس‌بندی کننده دوتایی $K(K-1)/2$ است و هر کلاس در K-1 مدل استفاده می‌شود [۱۲].



شکل ۳. روش کلاس‌بندی یکی در برابر همه برای حالت کلاسه ۴ [۶]

۵-۲. روش یکی در برابر یکی (OVO)

قدیمی‌ترین روش کلاس‌بندی چند کلاسه ماشین بردار پشتیبان احتمالاً روش یکی در برابر یکی است [۱۱]. در این روش برای کلاس‌بندی K کلاسه، K کلاس‌بندی کننده دوتایی ماشین بردار پشتیبان در نظر گرفته شده است. هر کلاس‌بندی کننده برای متمایز کردن یک کلاس از دیگر کلاس‌های باقی‌مانده آموزش داده می‌شود [۸].



شکل ۴. روش کلاس‌بندی یکی در برابر یکی برای حالت کلاسه ۴ [۶]

۵-۳. روش گراف غیرچرخشی جهت‌دار (DAG)

گراف غیرچرخشی جهت‌دار بر پایه گراف غیرچرخشی مستقیم ماشین بردار پشتیبان استوار است. این روش یکی از روش‌های کلاس‌بندی چند کلاسه است که توسط پلات [۱۱ و ۱۳] ارائه شده است و در آن فاز آموزش دقیقاً مشابه با روش یکی در برابر یکی اعمال می‌شود، بنابراین این روش از $K(K-1)/2$ کلاس‌بندی کننده دوتایی استفاده می‌کند با این تفاوت که این روش خود را در فاز کلاس‌بندی به وسیله یک ساختار درختی دوتایی ریشه‌ای با $K(K-1)/2$ گره داخلی و K برگ متمایز می‌کند. هر گره در این گراف شامل یک کلاس‌بندی کننده دوتایی از i مین و j مین کلاس است.

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

جدول ۱. توابع کرنل متداول [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	$\exp\left(\frac{-\lambda \ x - x_i\ ^2}{2\sigma}\right)$	λ, σ

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

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

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

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


۵. روش‌های کلاس‌بندی چند کلاسه

روش SVM یک دسته‌بندی کننده دوتایی است. در مورد مسائل چند کلاسی رهیافت کلی، کاهش مسئله چند کلاسی به چندین مسئله دوتایی است. سپس خروجی‌های دسته‌بندی کننده‌های دوتایی با هم ترکیب شده و به این ترتیب مسئله چند کلاسی حل می‌شود. برای کلاس‌بندی 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 جهت‌دار.


۵-۱. روش یکی در برابر همه (OVA)

این روش کلاس‌بندی به وسیله فریدمن [۱۰] پیشنهاد شد که یکی از مرسوم‌ترین و موفق‌ترین روش‌های چند کلاسه ماشین بردار پشتیبان است. در این روش یک ماشین بردار پشتیبان دوتایی، برای هر یک از ترکیب کلاس‌های ممکن ساخته می‌شود. برای توصیف کلاس‌بندی کننده به شکل دیگر، مجموعه کلاس‌ها را C در نظر گرفته و سایز C را

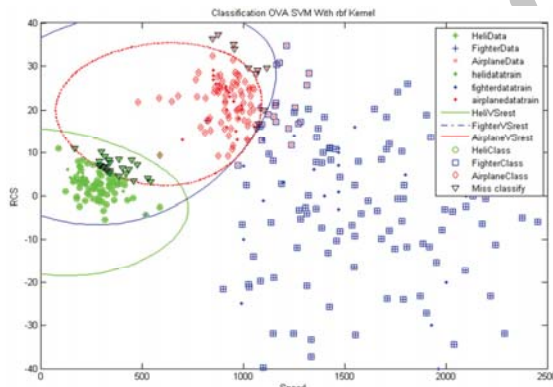
^۱ Radial Basis Function



شکل ۶. کلاس‌بندی OVA SVM با کرنل خطی




شکل ۷. کلاس‌بندی OVA SVM با کرنل چند جمله‌ای



شکل ۸. کلاس‌بندی OVA SVM با کرنل rbf

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




شکل ۵. روش گراف غیرچرخشی جهت‌دار برای حالت ۴ کلاسه [۱۲]


۶. شبیه‌سازی

ابتدا از ۶۰ داده آموزشی که متشکل از ۲۰ داده هواپیمای مسافری، ۲۰ داده هواپیمای جنگنده و ۲۰ داده هلی کوپتر است، برای آموزش شبکه‌ها استفاده می‌شود. با استفاده از مدل مخروطی گوسی ۳۰۰ داده آزمون متشکل از ۱۰۰ داده هواپیمای مسافری، ۱۰۰ داده هواپیمای جنگنده و ۱۰۰ داده هلی کوپتر ایجاد شده است. داده‌ها با استفاده از دو ویژگی سرعت و سطح مقطع راداری توصیف شده‌اند. در این مقاله با توجه به اینکه داده‌ها به صورت خطی به خوبی قابل تفکیک نیستند، برای دست‌یابی به کلاس‌بندی مطلوب از توابع کرنل در SVM استفاده شده است. بر این اساس عملکرد توابع کرنل برای هر کدام از روش‌های کلاس‌بندی چند کلاسه SVM مورد ارزیابی قرار خواهد گرفت.

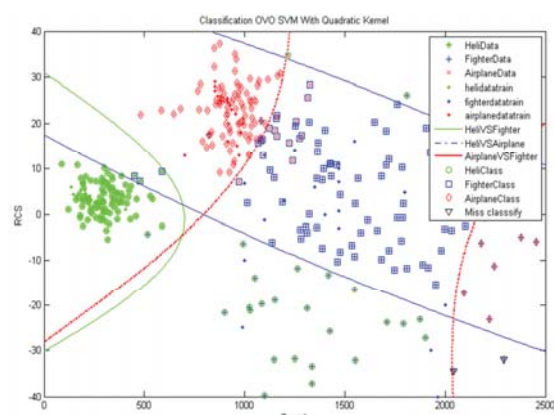
همان‌طور که در شکل‌های زیر مشخص است، داده‌های هلی کوپتر با رنگ سبز، داده‌های جنگنده با رنگ آبی و داده‌های مسافری با رنگ قرمز مشخص شده‌اند. ابتدا با ۶۰ داده آموزشی، شبکه ماشین بردار پشتیبان را آموزش داده، سپس با استفاده از بردارهای پشتیبان مشخص شده، داده‌های آزمون کلاس‌بندی می‌شوند. در این مقاله از سه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




شکل ۱۲. کلاس بندی OVO SVM با کرنل rbf




شکل ۹. کلاس بندی OVA SVM با کرنل quadratic



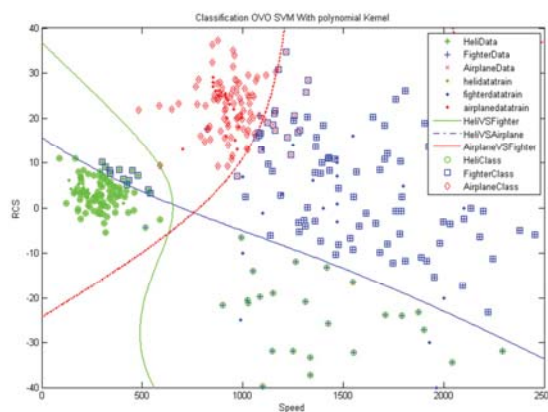
شکل ۱۳. کلاس بندی OVO SVM با کرنل quadratic



شکل ۱۰. کلاس بندی OVO SVM با کرنل خطی




شکل ۱۴. کلاس بندی DAG SVM با کرنل خطی




شکل ۱۱. کلاس بندی OVO SVM با کرنل چند جمله ای

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

به منظور ارزیابی، دقت کلاس بندی سه روش با کرنل های مختلف و سرعت اجرای الگوریتم های هر روش محاسبه می شود. برای ارزیابی دقت کلاس بندی، الگوریتم های کلاس بندی برای ۱۰۰۰ تکرار مختلف با داده های آزمون متفاوت اجرا شده اند و میانگین مربعات خطا برای هر روش در هر اجرا به دست آمده است. نتایج این ارزیابی در شکل (۱۸) آمده است. در روش یکی برابر همه کلاس بندی با استفاده از کرنل چند جمله ای نسبت به دیگر کرنل ها دقت بیشتری دارد، اما کرنل خطی دارای دقت بسیار پایینی است. در روش یکی در برابر یکی



شکل ۱۸. مقایسه میانگین مربعات خطا برای کرنل های مختلف



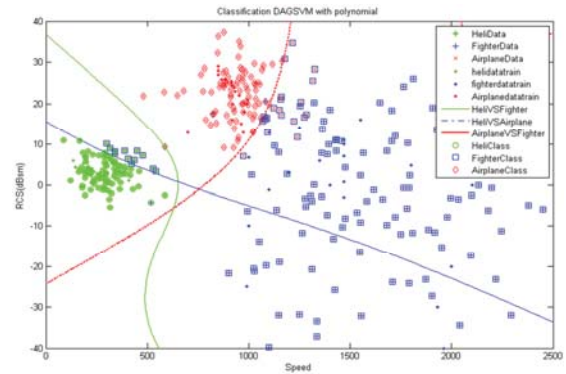
شکل ۱۹. مقایسه زمان اجرا برای کرنل های مختلف

۷. نتیجه گیری


کلاس بندی اهداف یکی از موضوعات مهم در سامانه های رادار است. روش های مختلفی برای کلاس بندی استفاده می شود که از مهم ترین روش های ارائه شده در این زمینه روش ماشین بردار پشتیبان است. اساساً روش SVM برای کلاس بندی دوتایی طراحی شده است، اما با استفاده از تکنیک هایی از آن نیز برای کلاس بندی چند کلاسه استفاده می شود. در این مقاله روش SVM برای کلاس بندی اهداف هوایی مورد بررسی قرار گرفتند. در میان روش های کلاس بندی چند کلاسه SVM، از روش های یکی در برابر همه، یکی در برابر یکی و گراف غیر چرخشی جهت دار در این مقاله بهره گرفته شد. از معیار میانگین مربعات خطا برای بررسی دقت کلاس بندی استفاده شد. در مواقعی که کلاس ها به صورت خطی به خوبی قابل تفکیک نیستند، می بایست از توابع کرنل غیر خطی استفاده کرد. با توجه به نتایج به دست آمده در این سه روش مذکور، روش گراف غیر چرخشی جهت دار 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 می کند. در این مقاله سرعت اجرای سه روش نیز مورد بررسی قرار گرفت، که نتایج به دست آمده نشان می دهد که سه روش دارای سرعت اجرای یکسانی می باشند.

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


برای حالتی که کلاس ها به طور خطی به خوبی قابل تفکیک نیستند، استفاده از توابع کرنل خطی عملکرد بسیار پایینی دارد و می بایست از توابع کرنل غیر خطی استفاده کرد.



شکل ۱۵. کلاس بندی DAG SVM با کرنل چند جمله ای



شکل ۱۶. کلاس بندی DAG SVM با کرنل rbf



شکل ۱۷. کلاس بندی DAG SVM با کرنل quadratic

^۱ Quadratic

۸. مراجع

- [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] Aioli, 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. Scholkopf, C. J. C. Burges, and A. J. Smole, 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.
- [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.

Archive of SID