

ارائه روشی برای کلاس‌بندی اهداف دریایی سوناری با استفاده از الگوریتم‌های چند کلاسه ماشین بردار پشتیبان

علی شعبانی^۱، سید محمد علوی^۲

چکیده

استفاده از سونار به دلیل بهره‌گیری از سیگنال‌های صوتی، روشی مناسب برای شناسایی و ردگیری اهداف زیر آبی است. از سوی دیگر کلاس‌بندی دقیق و صحیح اهداف برای تصمیم‌گیری درست امری ضروری است. روشی که در این مقاله برای کلاس‌بندی اهداف دریایی ارائه شده است، استفاده از الگوریتم‌های چند کلاسه ماشین بردار پشتیبان برای تفکیک اهداف می‌باشد. در اینجا اهداف مورد نظر عبارت‌اند از: غواص، ماهی، اژدر و زیردریایی که برای کلاس‌بندی آن‌ها از ویژگی‌های قدرت هدف و سرعت هدف استفاده شده است. در این مقاله برای نخستین بار و بر اساس این دو ویژگی و با استفاده از الگوریتم‌های چند کلاسه‌ی یکی در برابر یکی، یکی در برابر همه و گراف غیرچرخشی جهت‌دار اهداف مورد نظر از یکدیگر تفکیک شده و نتایج حاصل به کمک نرم‌افزار متلب شبیه‌سازی شده‌اند. در انتها عملکرد الگوریتم‌های یادشده بر اساس دو معیار دقت و زمان انجام کلاس‌بندی مورد ارزیابی قرار گرفته‌اند.

واژه‌های کلیدی

کلاس‌بندی اهداف، ماشین بردار پشتیبان (SVM)، روش یکی در برابر یکی، روش یکی در برابر همه، روش گراف غیرچرخشی جهت‌دار

مقدمه

امروزه با پیشرفت سلاح و جنگ‌افزارهای مورد استفاده در حوزه‌ی دریا، بالا بردن توان پدافندی در این حوزه امری ضروری و اجتناب‌ناپذیر است. زیردریایی‌ها، ROV^۳، AUV^۴ و سونارها از جمله ابزارهایی هستند که در دریا و برای کاربردهای تهاجمی و دفاعی مورد استفاده قرار می‌گیرند. استفاده از سونار به دلیل ویژگی‌های سیگنال آکوستیکی و امکان انتشار آسان آن در آب دریا، یکی از مناسب‌ترین روش‌ها برای شناسایی اهداف زیر آبی می‌باشد. سونارها در حالت کلی به دو نوع اکتیو و پسیو تقسیم می‌شوند که اطلاعاتی کلی در مورد آنها در مرجع [۱] وجود دارد.

عملکرد سونار اکتیو به این صورت است که صوتی را توسط فرستنده در آب منتشر می‌کند و این صوت پس از برخورد به اهداف مختلف و در راه بازگشت، توسط گیرنده سونار دریافت شده و مورد تجزیه و تحلیل قرار می‌گیرد. ولی در سونار پسیو فقط گیرنده وجود دارد که اصوات تولیدی از منابع و اهداف مختلف را دریافت و تجزیه و تحلیل می‌کند. نکته‌ای که وجود دارد این است که ما بتوانیم بر حسب ویژگی‌های خاصی که اهداف مختلف دارند (مانند: قدرت هدف، سرعت و ...)، منبع تولیدکننده صوتی که گیرنده سونار دریافت می‌کند را به درستی تشخیص داده و با دقت بالایی تعیین کنیم که با چه هدفی مواجه هستیم. از جمله اهدافی که شناسایی آن‌ها برای سونار اهمیت دارد می‌توان غواص، ماهی، اژدر و زیردریایی را نام برد که هر کدام برای کاربردهای خاصی اهمیت دارند. در این مقاله برای نخستین بار کلاس‌بندی این اهداف دریایی بر اساس قدرت سیگنال بازگشتی صورت گرفته است.

همان‌طور که بیان شد در موارد مختلف برای تصمیم‌گیری درست باید بتوان اهداف را به درستی و با دقت از یکدیگر تفکیک کرد. در این مقاله روشی ارائه می‌شود که برپایه ماشین

^۱ دانشجوی کارشناسی ارشد مخابرات، دانشگاه جامع امام حسین(ع)، ali.nujan@yahoo.com

^۲ استادیار دانشکده برق، دانشگاه جامع امام حسین(ع)

^۳ Remotely Operated Vehicle

^۴ Autonomous Underwater Vehicle (AUV)

تاریخ دریافت: ۱۵ آبان ۱۳۹۲ تاریخ پذیرش: ۱۶ آذر ۱۳۹۲

انجام کلاس‌بندی، روش‌های مورد بحث با یکدیگر مورد ارزیابی و مقایسه قرار گرفته شده‌اند. در قسمت چهارم نتیجه‌گیری بحث بیان شده و در آخر در قسمت پنجم مراجع استفاده شده معرفی شده است.

مفاهیم اولیه

مدل مخلوطی گوسی

مدل مخلوطی گوسی روشی است که به کمک آن می‌توان داده‌هایی با میانگین و واریانس مشخص و با توزیع گوسی تولید کرد که در مسائل کلاس‌بندی، برای تولید داده‌های آموزشی و مصنوعی از آن استفاده می‌شود.

در این مقاله برای تولید داده‌های مصنوعی از روی داده‌های آموزشی، از این مدل استفاده شده است (بجز داده‌های مربوط به غواص). برای این منظور ابتدا میانگین و واریانس سه کلاس داده‌های آموزشی استخراج شده و سپس تعداد ۳۰۰ داده مصنوعی برای آزمایش به این روش تولید می‌شود. البته ۱۰۰ داده مصنوعی مربوط به غواص به روشی دیگر تولید می‌شود که در جای خود بیان خواهد شد.

مدل مخلوطی کلی را می‌توان به صورت زیر نشان داد [۶]:

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

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.

$$f_k(x) = \left(\frac{1}{\sigma\sqrt{2\pi}} \right) \exp(0 - (x - \mu)^2 / (2\sigma^2)) \quad (2)$$

که در آن پارامتر σ^2 واریانس و μ مقدار میانگین یک مؤلفه مخلوطی است. در اینجا برای شبیه‌سازی انجام شده، از یک توزیع گوسی برای تولید داده‌های مصنوعی استفاده شده و لذا $c_k = K = 1$ در نظر گرفته شده است.

ماشین بردار پشتیبان

در این بخش مقدمه‌ای بر ماشین‌های بردار پشتیبان ارائه می‌شود. مسئله‌ای کلاس‌بندی دوتایی در نظر گرفته می‌شود که

بردار پشتیبان^۵، اقدام به کلاس‌بندی اهداف دریایی بر اساس ویژگی‌های قدرت هدف^۶ و سرعت اهداف می‌شود.

ماشین بردار پشتیبان اولین بار توسط واپنیک^۷ ارائه شد که عموماً برای کلاس‌بندی دوتایی طراحی شده است [۲] و بارجس^۸ از آن به منظور شناسایی الگوها استفاده کرد [۳]. در این مقاله از روش‌های چند کلاسه برای کلاس‌بندی اهداف استفاده شده است. روش کلاس‌بندی کلاسیک ماشین بردار پشتیبان، تنها برای مسائل دسته‌بندی دوتایی قابل استفاده است که در این موارد برچسب کلاس‌ها تنها دو مقدار +۱ و -۱ می‌باشند درحالی‌که در عمل بسیاری از مسائل چند کلاسه هستند.

در این مقاله برای حل مسئله چند کلاسه پیش رو از سه دسته روش برای تعمیم ماشین بردار پشتیبان ارائه شده است که این سه دسته روش عبارت‌اند از: یکی در برابر یکی^۹، یکی در برابر همه^{۱۰} و گراف غیرچرخشی جهت‌دار^{۱۱}.

هر کدام از این روش‌ها مزایا و معایبی دارند [۴]. باید توجه داشت که معیار دقیق و مشخصی برای انتخاب یکی از این روش‌ها وجود ندارد و این عمل بنا بر دقت مورد نظر، زمان انجام یادگیری و دسته‌بندی، تعداد بردارهای پشتیبان و نوع توزیع کلاس‌ها در مسائل مختلف صورت می‌گیرد. در الگوریتم کلاس‌بندی، نمونه‌ها با استفاده از بردار ویژگی‌های اهداف دسته‌بندی می‌شوند. حال یک روش استقرایی تابعی را می‌سازد که قادر خواهد بود هر نمونه آزمون داده شده را با ویژگی‌های مشابه در یکی از کلاس‌های موجود قرار دهد [۵]. در بیشتر موارد می‌بایست به وسیله یک ابر صفحه جداکننده غیرخطی کلاس‌ها را از هم جدا کرد. در این موارد داده‌ها می‌توانند به کمک یک تابع تبدیل غیرخطی به یک فضای با ابعاد بیشتر نگاشت شوند و بدین ترتیب با افزودن ابعاد بیشتر به داده‌ها یک ابر صفحه جداکننده خطی می‌تواند کلاس‌ها را از هم جدا کند.

در ادامه و در بخش دوم مقاله، مفاهیم اولیه شامل مدل مخلوطی گوسی^{۱۲}، ماشین بردار پشتیبان، کلاس‌بندی چند کلاسه و توابع کرنل توضیح داده شده است. در بخش سوم نتایج شبیه‌سازی برای کلاس‌بندی داده‌های آموزشی و مصنوعی به سه روش مورد نظر شامل یکی در برابر یکی، یکی در برابر همه و گراف غیر چرخشی جهت‌دار نشان داده شده است و سپس با استفاده از دو معیار میانگین مربعات خطا و زمان

Support Vector Machine (SVM)	۵
Target Strength (TS)	۶
V. Vapnik	۷
C.J.C. Burges	۸
One Vs. One	۹
One Vs. Rest	۱۰
Direct Acyclic Graph (DAG)	۱۱
Gaussian Mixture Model (GMM)	۱۲

در فرمول (۵) α_i ها ضرایب لاگرانژ هستند که حل مسئله بهینه‌سازی داده‌شده در این فرمول ضرایب مربوطه را به دست می‌دهد. بر اساس شرایط بهینگی KKT^{۱۳} برخی ضرایب صفر خواهند شد. ضرایبی که مقدار غیر صفر دارند بردار پشتیبان نامیده می‌شوند. نتایج به دست آمده از بهینه‌سازی، مجموعه $w^o = (\alpha_1^o, \dots, \alpha_k^o)$ می‌باشد که پاسخ بهینه است. مقدار w^o و b^o با استفاده از فرمول‌های زیر محاسبه می‌شوند:

$$w^o = \sum_{i=1}^k y_i \alpha_i^o x_i \quad (7)$$

$$b^o = \frac{1}{2} [w^o \cdot x_{+1}^o + w^o \cdot x_{-1}^o] \quad (8)$$

که در اینجا x_{+1}^o و x_{-1}^o به ترتیب بردارهای پشتیبان کلاس‌های +۱ و -۱ می‌باشند. تصمیم‌گیری به منظور کلاس‌بندی مجموعه داده‌ها به دو کلاس +۱ و -۱ به صورت زیر انجام می‌گیرد.

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

که $\text{sign}(\cdot)$ تابع علامت می‌باشد. این تابع +۱ را برای عناصر بزرگ‌تر یا مساوی صفر و -۱ را برای عناصر کوچک‌تر از صفر اختصاص می‌دهد [۸].

کلاس‌بندی چند کلاسه

برای حل بسیاری از مسائلی که در عمل با آن‌ها مواجه‌ایم ناچاریم از روش‌های کلاس‌بندی چند کلاسه استفاده کنیم ولی همان‌طور که قبلاً ذکر شد ماشین‌های بردار پشتیبان، کلاس‌بندی‌کننده‌های ذاتاً دوتایی هستند بنابراین تکنیک‌هایی نیاز است که این روش‌ها را برای حل مسائل چند کلاسه تعمیم دهد. در ادامه این روش‌های مختلف شرح داده می‌شوند.

روش یکی در برابر یکی

این روش به وسیله فریدمن^{۱۴} پیشنهاد شده است و یکی از مرسوم‌ترین و موفق‌ترین روش‌های چند کلاسه ماشین بردار پشتیبان می‌باشد [۹][۱۰]. روند کار در این روش به این صورت است که یک ماشین بردار پشتیبان دوتایی برای هر یک از

مجموعه داده‌های داده شده در آن به وسیله یک ابرصفحه جداکننده خطی قابل دسته‌بندی به دو کلاس باشند، با فرض اینکه مجموعه داده‌های آموزشی شامل k نمونه آموزشی نشان داده شده به وسیله $(x_1, y_1), \dots, (x_k, y_k)$ باشند. جایی که $x_i \in R^N$ یک بردار داده N بعدی بوده و هر نمونه آن متعلق به یکی از دو کلاس $y_i \in \{-1, 1\}$ است. هدف ماشین بردار پشتیبان پیدا کردن یک تابع تصمیم‌گیری خطی تعریف شده به وسیله $f(x) = w \cdot x + b$ است، جایی که $w \in R^N$ جهت ابرصفحه جداکننده را تعیین می‌کند و $b \in R$ یک بایاس است. ابرصفحه‌ها برای دو کلاسه به صورت $y_i(w \cdot x + b) \geq 1$ نمایش داده می‌شوند. گاهی اوقات به علت وجود نویز یا تداخل کلاس‌های معرفی‌شده در طی انتخاب داده‌های آموزشی، از متغیر $\xi_i \geq 0$ که متغیر کمکی نامیده می‌شود برای نمایش اثر کلاس‌بندی اشتباه استفاده می‌شود. بر این اساس و با در نظر گرفتن ξ_i ابر صفحه‌ها برای دو کلاسه‌ها به صورت $y_i(w \cdot x + b) \geq 1 - \xi_i$ نشان داده می‌شوند [۷]. ابر صفحه بهینه (یعنی $f(x) = 0$) در جایی قرار می‌گیرد که حاشیه بین دو کلاس مورد نظر بیشینه بوده و در عین حال خطای آن کمینه باشد که این می‌تواند به وسیله حل مسئله بهینه‌سازی زیر به دست آید.

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \quad (3) \text{ کمینه سازی تابع:}$$

$$y_i(w \cdot x + b) \geq 1 - \xi_i \text{ for } i=1, 2, \dots, k \quad (4) \text{ با شرط:}$$

مقدار ثابت $0 < C < \infty$ که مقدار هزینه نامیده می‌شود یک پارامتر قابل تنظیم است. این مقدار، مصالحه‌ای بین تعداد کلاس‌بندی‌های اشتباه در داده‌های آموزشی و بیشینه حاشیه را تعریف می‌کند. در عمل مقدار هزینه بوسیله روش آزمایش و خطا تعیین می‌شود. مسئله بهینه‌سازی (۳) به وسیله روش لاگرانژ حل می‌شود. مسئله بهینه‌سازی با فرمول‌های زیر معادل می‌شود:

$$\sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (5) \text{ بیشینه تابع:}$$

$$\sum_{i=1}^k \alpha_i y_i = 0 \text{ \& } 0 \leq \alpha_i \leq C \text{ for } i=1, \dots, k \quad (6) \text{ با شرط:}$$

^{۱۳} Karush-Kuhn-Tucker
^{۱۴} Friedmann


توابع کرنل

برای مسائلی که یک ابرصفحه تصمیم‌گیری غیرخطی دارند، یک تابع نگاشت $\phi(x)$ برای انتقال داده‌های اصلی به یک فضای ویژگی با ابعاد بالاتر استفاده می‌شود. در این موارد 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 [۱۱].

$$k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (10)$$

تابع k یک کرنل نامیده می‌شود و SVM ها یک عضو از کلاس گسترده از روش‌های کرنل هستند [۱۳].

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



شکل ۲. نمایش نقش کرنل در یک مسئله کلاس‌بندی [۱۱]

در یک تابع کرنل بجای ضرب نقطه‌ای، بردارهای تبدیل یافته جایگزین می‌شوند و شکل واضح و روشن تابع تبدیل $\phi(x)$ لزوماً شناخته شده نیست. بعلاوه استفاده از تابع کرنل به شدت به محاسبات کمتری نیاز دارد. فرمول‌بندی تابع کرنل از ضرب نقطه‌ای یک مورد خاص از نظریهٔ مرکز می‌باشد. مسئلهٔ بهینه‌سازی به صورت زیر در می‌آید:

$$\sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (11) \text{ بیشینه:}$$


ترکیب کلاس‌های ممکن ساخته می‌شود. برای توصیف کلاس-بندی کننده، مجموعهٔ کلاس‌ها C و سایز آن‌ها K در نظر گرفته می‌شود. تعداد نتایج کلاس‌بندی کنندهٔ دوتایی $K(K-1)/2$ بوده و هر کلاس در $K-1$ مدل استفاده می‌شود [۱۱].

روش یکی در برابر همه

روش یکی در برابر همه احتمالاً قدیمی‌ترین روش کلاس‌بندی چند کلاسه ماشین بردار پشتیبان می‌باشد. در این روش برای کلاس‌بندی K کلاسه، به تعداد K کلاس‌بندی کنندهٔ دوتایی ماشین بردار پشتیبان نیاز است. هر کلاس‌بندی کننده برای متمایز کردن یک کلاس از دیگر کلاس‌های باقیمانده آموزش داده می‌شود [۷][۴].

گراف غیر چرخشی جهت‌دار


این روش یکی از روش‌های کلاس‌بندی چند کلاسه می‌باشد که توسط پلات^{۱۵} ارائه شده است و بر پایهٔ گراف غیر چرخشی مستقیم ماشین بردار پشتیبان استوار است (شکل ۱). در این روش فاز آموزش دقیقاً مشابه با روش یکی در برابر یکی می‌باشد. بر این اساس، 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 z مین کلاس می‌باشد. شکل ۱ ساختار این روش را برای یک حالت چهار کلاسه نشان می‌دهد [۱۲].



شکل ۱. روش گراف غیر چرخشی جهت‌دار برای حالت چهار کلاسه [۱۱]


^{۱۵} Mercers Theorem

^{۱۶} Platt




شکل ۳. داده‌های مورد استفاده برای آموزش

دستور Svmtrain در متلب برای آموزش دوتایی به منظور انجام کلاس‌بندی وجود دارد اما برای آموزش چند کلاسه چنین دستوری موجود نیست. بر این اساس الگوریتم‌های چند کلاسه‌ای که در بالا شرح داده شد، برای مرحله آموزش پیاده‌سازی شد. شکل‌های مربوط به کلاس‌بندی داده‌های آموزشی به روش یکی در برابر یکی در شکل (۴) و روش یکی در برابر همه در شکل (۵) نشان داده شده است.



شکل ۴. کلاس‌بندی داده‌های آموزش بر اساس الگوریتم یکی در برابر یکی



شکل ۵. کلاس‌بندی داده‌های آموزش بر اساس الگوریتم یکی در برابر همه

لازم به ذکر است که آموزش برای روش گراف غیر چرخشی جهت‌دار، دقیقاً مشابه روش یکی در برابر یکی می‌باشد. بنابراین از آوردن شکل مربوط به مرحله آموزش برای این روش خودداری شده است.

در مرحله بعد و برای ارزیابی الگوریتم ماشین بردار پشتیبان، باید این الگوریتم را برای داده‌های مصنوعی، که از داده‌های

$$\sum_{i=1}^k \alpha_i y_i = 0 \text{ \& } 0 \leq \alpha_i \leq C \text{ for } i=1, \dots, k \quad (12) \text{ با شرط:}$$

پس تابع تصمیم‌گیری به صورت زیر می‌شود:

$$f(x) = \text{sign} \left(\sum_{\text{Support Vector}} y_i \alpha_i K(x_i, x) + b^o \right) \quad (13)$$

توابع کرنل مرسوم در جدول (۱) لیست شده است [۱۴][۱۵].

تعریف توابع	توابع کرنل
$x \cdot x_i$	Linear
$\tanh(\lambda x \cdot x_i + r)$	Quadratic
$(\lambda x \cdot x_i + r)^d$	Polynomial
$\exp\left(\frac{-\lambda \ x - x_i\ ^2}{2\sigma}\right)$	RBF

جدول ۱. توابع کرنل مرسوم


شبیه‌سازی

شبیه‌سازی‌ها در چند مرحله شامل: تولید و کلاس‌بندی داده‌های آموزشی، تولید و کلاس‌بندی داده‌های مصنوعی بر اساس الگوریتم‌های مختلف انجام و در آخر ارزیابی عملکرد این الگوریتم‌ها طبق معیارهای دقت و زمان انجام کلاس‌بندی انجام شده‌اند. اولین مرحله برای انجام شبیه‌سازی‌های لازم، تولید داده‌های آموزشی است. برای هر کلاس ۱۰ نمونه آموزشی انتخاب شده است. برای غواص، ماهی و اژدر از داده‌های آموزشی [۱۶] استفاده شده است. ۱۰ داده آموزشی برای زیردریایی نیز از [۱۸] گرفته شده است. شکل (۳) این داده‌های آموزشی را نمایش می‌دهد. در این شکل محور عمودی سرعت اهداف و محور افقی قدرت هدف اهداف را نشان می‌دهد.

با نقاط آبی رنگ و دایره قرمز رنگ مشخص شده است. داده‌های آزمون اژدر و زیردریایی به ترتیب با علامت جمع و نقاط مشکی و کلاس‌های مربوط به آن‌ها با مربع مشکی و لوزی قرمز نشان داده شده است. همان طور که شکل نشان می‌دهد بعضی نقاط سبز در دایره‌های قرمز قرار گرفته‌اند و این به معنی آن است که کلاس کننده به اشتباه ماهی را غواص تشخیص داده است. و همچنین بعضی نقاط سبز در مربع سیاه واقع شده که نشانه آن است که ماهی به اشتباه در کلاس اژدر قرار گرفته است. به همین صورت اشتباهات دیگری که کلاس کننده برای سایر اهداف مرتکب شده است را می‌توان با توجه به شکل مشاهده کرد.


در شکل (۸) نیز داده‌های آزمون مربوط به غواص، ماهی، اژدر و زیردریایی به ترتیب با: نقاط آبی، نقاط سبز، علامت جمع و نقاط سیاه رنگ مشخص شده است و کلاس‌های مربوط با این اهداف به ترتیب با: دایره قرمز، مثلث قرمز، مثلث سیاه و مربع آبی نشان داده شده است. با دقت به شکل مشخص می‌شود که کلاس‌بندی کننده مخصوصاً در مورد زیردریایی دچار خطای زیادی شده است و همچنین بعضی داده‌ها در هیچ‌کدام از کلاس‌ها قرار ندارند که به معنی عدم توانایی کلاس‌بندی کلاس کننده در مورد آن‌ها است.

در شکل (۹) داده‌های آزمون مربوط به ماهی با نقاط سبز رنگ و کلاس مربوط به این هدف با مربع سیاه رنگ مشخص شده است و همچنین برای غواص داده‌های آزمون و کلاس به ترتیب با نقاط آبی رنگ و دایره قرمز رنگ مشخص شده است. داده‌های آزمون اژدر و زیردریایی به ترتیب با علامت جمع و نقاط مشکی و کلاس‌های مربوط به آن‌ها با مربع قرمز و مربع فیروزه‌ای نشان داده شده است. همان طور که شکل نشان می‌دهد بعضی نقاط سبز در دایره‌های قرمز قرار گرفته‌اند و این به معنی آن است که کلاس کننده به اشتباه ماهی را غواص تشخیص داده است. و همچنین بعضی علائم جمع در مربع فیروزه‌ای واقع شده که نشانه آن است که اژدر به اشتباه در کلاس زیردریایی قرار گرفته است.



شکل ۷. کلاس‌بندی داده‌های مصنوعی بر اساس الگوریتم یکی در برابر یکی

آموزشی تولید می‌شوند اجرا کردو به همین منظور برای هر کلاس ۱۰۰ داده مصنوعی تولید شده است. داده‌های مصنوعی مربوط به غواص به روش گفته شده در [۱۶] تولید شده است. داده‌های مصنوعی برای بقیه کلاس‌ها از روش مدل مخلوطی گوسی تولید شده‌اند. در شکل (۶) داده‌های مصنوعی استفاده شده نمایش داده شده است. محور افقی در این شکل سرعت و محور عمودی قدرت هدف را نشان می‌دهد.




شکل ۶. داده‌های مصنوعی مورد استفاده برای کلاس‌بندی

در مرحله کلاس‌بندی نیز دستور Svmclassify در متلب به منظور کلاس‌بندی دوتایی در اختیار است که متضمن استفاده از فرمول‌های ۳ الی ۹ ارائه شده در مقاله می‌باشد. اما این دستور به تنهایی برای بهره‌گیری از ماشین بردار پشتیبان برای حل مسئله چند کلاسه پیش رو قابل استفاده نبوده و به همین دلیل الگوریتم‌های ارائه شده پیاده‌سازی شده‌اند.


در این مرحله از شبیه‌سازی، ۴۰۰ داده آزمون قبلی بر اساس روش‌های ذکر شده بالا کلاس‌بندی می‌شوند. شکل‌های (۷)، (۸) و (۹) به ترتیب کلاس‌بندی را برای روش‌های یکی در برابر یکی، یکی در برابر همه و گراف غیر چرخشی جهت‌دار نشان می‌دهند. در این شکل‌ها نیز محور افقی سرعت اهداف و محور عمودی قدرت هدف می‌باشد.

در روش گراف غیر چرخشی جهت‌دار ابتدا دو دسته از داده‌ها که در فاصله دورتری قرار گرفته و بهتر تفکیک می‌شوند در نظر گرفته شده و ابتدا کلاس‌بندی دوتایی روی آن‌ها صورت می‌گیرد. در این مسئله داده‌های مربوط به غواص و اژدر این شرط را دارا می‌باشند که به ترتیب در کلاس‌های اول و دوم قرار گرفته‌اند. واضح است که در این حالت داده‌های هر کلاس شامل داده‌هایی از کلاس سوم و چهارم که به ترتیب معرف زیردریایی و ماهی می‌باشند نیز هستند. حال در هر کلاس مسئله کلاس‌بندی، بین آن کلاس و کلاس سوم و چهارم مطرح می‌شود که این کار مطابق شکل (۱) در دو مرحله انجام می‌شود. نتایج کلاس‌بندی به روش گراف غیر چرخشی جهت‌دار در شکل (۹) نشان داده شده است.

در شکل (۷) داده‌های آزمون مربوط به ماهی با نقاط سبز رنگ و کلاس مربوط به این هدف با مثلث سیاه رنگ مشخص شده است و همچنین برای غواص داده‌های آزمون و کلاس به ترتیب




شکل ۱۰. مقایسه زمان اجرای برنامه




شکل ۱۱. مقایسه میانگین مربعات خطا

نتیجه گیری

یکی از مناسب‌ترین روش‌ها برای شناسایی و ردگیری اهداف زیر آب استفاده از سونار است. همچنین یکی از مباحث مهم در زمینه شناسایی اهداف، بحث کلاس‌بندی اهداف است. در این مقاله برای تفکیک چهار هدف دریایی: غواص، ماهی، اژدر و زیردریایی، بر اساس دو ویژگی سرعت و قدرت هدف، روشی بر پایه الگوریتم‌های کلاس‌بندی چند کلاسه ماشین بردار پشتیبان ارائه شده است. الگوریتم‌های استفاده شده در این مقاله الگوریتم‌های یکی در برابر یکی، یکی در برابر همه و گراف چرخشی جهت‌دار بودند. در ابتدا برای هر کدام از کلاس‌ها ۱۰ نمونه آموزشی انتخاب شد که نتیجه کلاس‌بندی این داده‌ها به وسیله الگوریتم‌های گفته‌شده در نرم‌افزار متلب شبیه‌سازی و نمایش داده‌شده است. در مرحله بعد توسط این داده‌های آموزشی، برای هر کلاس ۱۰۰ داده‌ی مصنوعی تولید شده و سپس الگوریتم‌های چند کلاسه بر این داده‌ها اعمال و نتیجه حاصل شبیه‌سازی و نمایش داده‌شده است. در آخر عملکرد این الگوریتم‌ها از نظر دقت و زمان کلاس‌بندی و آموزش مورد ارزیابی قرار گرفته است. طبق نتایج نشان داده‌شده الگوریتم یکی در برابر یکی کمترین زمان و الگوریتم گراف چرخشی جهت‌دار بیشترین دقت را دارند. با استفاده از روش بیان‌شده در این مقاله با دقت بالایی می‌توان به کلاس‌بندی اهداف دریایی سوناری ذکر شده اقدام کرد.



شکل ۸. کلاس‌بندی داده‌های مصنوعی بر اساس الگوریتم یکی در برابر همه



شکل ۹. کلاس‌بندی داده‌های مصنوعی بر اساس الگوریتم گراف غیر چرخشی جهت‌دار

مرحله ارزیابی

برای ارزیابی عملکرد روش‌ها، دو پارامتر سرعت و دقت مد نظر قرار گرفته است. به منظور ارزیابی سرعت اجرای الگوریتم در سه روش، زمان آموزش و کلاس‌بندی در هر کدام محاسبه شده‌اند. بر این اساس الگوریتم‌های کلاس‌بندی برای ۱۰۰۰ تکرار مختلف با داده‌های آزمون متفاوت اجرا شده و زمان هر اجرا محاسبه شده است. نتایج این ارزیابی در شکل (۱۰) آمده است. در این شکل محور عمودی، زمان اجرای الگوریتم کلاس‌بندی و محور افقی تعداد تکرار اجرای الگوریتم را نشان می‌دهد. مطابق نتایج به دست آمده زمان اجرای کمینه به ترتیب مربوط به یکی در برابر یکی، گراف غیر چرخشی جهت‌دار و روش یکی در برابر همه می‌باشد. برای ارزیابی دقت کلاس‌بندی روش‌ها از میانگین مربعات خطا استفاده می‌شود. بدین صورت که الگوریتم‌های کلاس‌بندی برای ۱۰۰۰ تکرار مختلف با داده‌های آزمون متفاوت اجرا شده و میانگین مربعات خطا برای هر اجرا به دست می‌آید. نتایج این ارزیابی نیز در شکل (۱۱) نشان داده‌شده است که در آن محور عمودی میانگین مربعات خطا و محور افقی تعداد تکرار را نشان می‌دهد. همان‌طور که شکل نشان می‌دهد بیشترین دقت مربوط به گراف غیر چرخشی جهت‌دار است.

مراجع

- [10] U. Krebel, "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*, pp. 255-268, Cambridge, MA, MIT Press, 1999.
- [11] J. Solomon, "Support Vector Machines For Phoneme Classification," Master Of Science, Schools Of Artificial Intelengece Division Of Informatics University Of Edinburg, pp. 34, 2001.
- [12] N. C. J. Platt, J. Shawe-Taylor, "Large Margin Dags For Multiclass Classification," Technical report, Microsoft Research, Redmond, US, 1999.
- [13] Schölkopf, B., Burges, C., Smola, A., "Introduction to support vector learning," In B. Schölkopf, C. Burges, and A. Smola, editors, *Advances in Kernel Methods- Support Vector Learning*, MIT Press, 1998.
- [14] P. Watanachaturaporn, M. K. Arora, P. K. Varshney, "Evaluation Of Factors Affecting Support Vector Machines For Hyperspectral Classification," in Proc. American Soc. Photogrammetry & Remote Sensing (ASPRS) 2004 Annual Conf., 2004.
- [15] M. C. Lee, To.Chang, "Comparison Of Support Vector Machine And Back Propagation Neural Network In Evaluating The Enterprise Financial Distress," *International Journal of Artificial Intelligence & Applications (IJAIA)*, Vol.1, No.3, July 2010.
- [16] علی شعبانی، مرتضی حاجی محمدی، سید محمد علوی "بهبود دقت شناسایی غواص با استفاده از الگوریتم کلاس‌بندی ماشین بردار پشتیبان". اولین همایش فناوری‌های نوین دریایی، نوشهر، ۱۳۹۲.
- [17] J. B. Conant, R. C. Tolman, R. Adams, F. B. Jewett, K. T. Compton, "Physics of Sound in the Sea," NDRC, Volume 8, Washington, D.C, 388, 1946.
- [1] R. P. Hodges, "Underwater Acoustics Analysis Design and Performance of Sonar," John Wiley, United Kingdom, vol. 1, pp. 1-30, 2010.
- [2] V. Vapnik, A. Lerner, "Pattern Recognition Using Generalized Portrait Method," *Automation and Remote Control*, vol. 24, pp. 774-780, 1963.
- [3] C.J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," *Data Mining and Knowledge Discovery*, vol. 2, pp. 955-974, 1998.
- [4] C.-W. Hsu and C. J. Lin, "A Comparison Methods for Multiclass Support Vector Machines," *IEEE Transaction on Neural Networks*, vol. 13, pp. 415-425, 2002.
- [5] F. Aioli, A. Sperduti, "Multiclass Classification with Multi-Prototype Support Vector Machines," *Dip. di Matematica Pura e Applicata, Università di Padova*, *Journal of Machine Learning Research* 6, pp. 817-850, 2005.
- [6] R. Balada, "Radar Signal Recognition Method Based On Gaussian Mixture Models," Doctoral Degree Programme, Fecc But.
- [7] P. Watanachaturaporn, M. K. Arora, and P. K. Varshney, "Evaluation Of Factors Affecting Support Vector Machines For Hyperspectral Classification," in Proc. American Soc. Photogrammetry & Remote Sensing (ASPRS) 2004 Annual Conf., 2004.
- [8] Q. Chang, Q. Chen, X. Wang, "Scaling Gaussian RBF Kernel Width To Improve SVM Classification," in *IEEE International Conference on Neural Networks and Brain, IC- NNB'05*, pp. 20, Oct 2005.
- [9] J.H. Friedman, "Another Approach To Polychotomous Classification," Technical report, Stanford Department of Statistics, 1996.