

مقایسه دقت و زمان کلاس‌بندی الگوریتم‌های ماشین بردار پشتیبان و شبکه عصبی برای شناسایی غواص

علی شعبانی^۱، سیدمحمد علوی^۲

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

۲. دکترای مهندسی برق و الکترونیک، استادیار دانشگاه جامع امام حسین (ع)

تاریخ دریافت: ۹۲/۸/۱۵ تاریخ پذیرش: ۹۳/۵/۵

چکیده

ویژگی‌های منحصر به فرد و امکان انتشار آسان سیگنال‌های صوتی در محیط زیر آب، امکان شناسایی و ردگیری اهداف زیر آبی بوسیله آنها را فراهم می‌کند. از جمله کاربردهای پدافندی سیگنال صوتی در حوزه دریای می‌توان استفاده از سونار برای شناسایی غواص به منظور جلوگیری از نفوذ غواصان در نیروگاه‌های ساحلی و همچنین حفاظت از تجهیزات بندرگاهی و... نام برد. برای این مقصود شناسایی صحیح غواص از سایر اهداف زیرآبی مانند: دلفین‌ها و توده ماهی‌ها اهمیت می‌یابد. در این مقاله برای شناسایی غواص از دو روش کلاس‌بندی اهداف ماشین بردار پشتیبان^۱ و شبکه عصبی استفاده شده است و برای این کار از دو ویژگی قدرت هدف^۱ و سرعت هدف بهره گرفته شده است. در انتها نتایج این روش‌ها براساس دقت و زمان کلاس‌بندی و شناسایی مورد ارزیابی قرار گرفته است. شبیه‌سازی‌ها نشان دهنده آن است که ماشین بردار پشتیبان با تابع کرنل RBF بهترین نتیجه را دارد.

کلیدواژه

سونار، شناسایی غواص، ماشین بردار پشتیبان (SVM)، شبکه عصبی، کلاس‌بندی اهداف، قدرت هدف (TS)

مقدمه

تجهیزات تنفسی غواص را بر حسب میزان حبایی که در هنگام شنا تولید می‌کنند می‌توان به سه گروه: تجهیزات مدار باز^۱، مدار نیمه بسته^۲، مدار بسته^۳ طبقه‌بندی کرد؛ که میزان حباب تولیدی آنها به ترتیب: زیاد، کم و بسیار کم است. گروه اول که حباب زیادی تولید می‌کنند برای غواصی ورزشی و تفریحی مورد استفاده قرار می‌گیرند ولی دسته دوم و سوم مخصوص عملیات‌های نظامی و جاسوسی می‌باشند. از آن جا که سونار غیرفعال برای شناسایی غواص از صدای ناشی از ترکیدن حباب‌های تنفسی غواص استفاده می‌کند کار شناسایی غواص با تجهیزات دسته دوم و سوم دشوار می‌باشد ولی سونار فعال از پارامتر قدرت هدف غواص برای شناسایی استفاده می‌کند [۲]. البته باید در نظر داشت که در محیط زیر آب موجودات دریایی چون: ماهی، دلفین و ... وجود دارند که ممکن است به اشتباه توسط سونار به عنوان غواص تشخیص داده شوند؛ به همین منظور باید از روش‌های کلاس‌بندی اهداف برای کاهش خطای تصمیم‌گیری سونار استفاده کرد. در این مقاله برای شناسایی و تفکیک غواص از انواع ماهی از دو روش کلاس‌بندی ماشین بردار پشتیبان و شبکه عصبی استفاده شده و نتایج حاصل از این روش‌ها به کمک نرم‌افزار MATLAB

یکی از بحث‌های مهم در صنایع دفاعی دریایی، محافظت از زیرساخت‌های دریایی از جمله: نیروگاه‌های برق کنار دریا، پل‌ها، و تجهیزات موجود در بندرگاه‌ها است. به جرأت می‌توان گفت یکی از خطرناک‌ترین تهدیدات برای این تجهیزات دریایی و ساحلی از ناحیه غواصان است که به راحتی می‌توانند با پنهان شدن در زیر آب در این نقاط حساس نفوذ کرده و صدمات جبران ناپذیری به آنها وارد سازند. با توجه به این مسئله اهمیت به‌کارگرفتن سیگنال‌های آکوستیکی و سونار برای آشکارسازی این خطرات و دفاع در برابر آنها مشخص می‌شود. از آنجا که سیگنال‌های آکوستیکی توانایی انتشار در بردهای طولانی در زیر آب را دارا می‌باشند، سونارها مؤثرترین وسیله برای استفاده در آشکارسازی و ردگیری اهداف در دریا هستند. سونارها در حالت کلی به دو نوع فعال و غیرفعال تقسیم می‌شوند. سونار فعال یک موج صوتی را درون آب ارسال می‌کند و این موج پس از منتشر شدن در محیط دریا و در اثر برخورد به اهداف و موانع موجود در مسیر خود، منعکس شده و به سمت گیرنده برمی‌گردد و سونار با تجزیه و تحلیل این اکوی بازگشتی به شناسایی اهداف می‌پردازد. در سونار غیرفعال، هدف، خود نقش یک منبع صوتی را بازی می‌کند و سونار با گوش دادن به اکوهای دریافتی از هدف به ردگیری و آشکارسازی آن می‌پردازد [۱].


1. Open circuit
2. Semi close circuit
3. Close circuit

$$TS = 10 \log t \quad (1)$$

$$t = \frac{aL^2}{2\lambda} \left(\frac{\sin(\beta)}{\beta} \right)^2 \cos^2(\theta) \quad (2)$$


$$\beta = kL \sin(\theta) \quad (3)$$

در فرمول‌های بالا L طول استوانه در واحد متر، a شعاع استوانه در واحد متر، θ زاویه بین خط عمود بر محور استوانه و پرتو تابشی و k عدد موج است. فرمول بالا توسط Kerf به دست آمده و او از این فرمول برای محاسبه میزان پراکندگی امواج رادیویی توسط استوانه محدود و کاملاً هادی استفاده کرده است [۱۰]. این فرمول بعدها توسط Urick برای محاسبه میزان پراکندگی امواج آکوستیک استفاده شد. شکل (۱) یک استوانه با طول محدود را در مقابل پرتو نشان می‌دهد.



شکل ۱. استوانه با طول محدود در مقابل پرتو [۳]

شکل (۲) شبیه‌سازی قدرت هدف یک استوانه با طول محدود و بر حسب مدل Urick را نشان می‌دهد. لازم به ذکر است که سرعت صوت در آب ۱۵۰۰ متر بر ثانیه، فرکانس کاری سونار ۶۰ کیلوهرتز، طول استوانه ۱/۸ متر و شعاع آن ۰/۱۲۵ متر در نظر گرفته شده است. در شکل (۲) محور عمودی، قدرت هدف استوانه‌ای است که از آن به عنوان مدلی برای غواص استفاده شده و محور افقی، زاویه θ در فرمول Urick است [۱۱].



شکل ۲. قدرت هدف استوانه با طول محدود [۱۱]

در مباحث مربوط به شکار ماهی برای پیدا کردن محل و تخمین حجم توده‌های ماهی از پارامتر قدرت هدف استفاده می‌شود؛ روند کار به این صورت است که وقتی سونار سیگنالی را ارسال می‌کند هر چه توده ماهی بزرگتر و تعداد ماهیان آن بیشتر باشد، قدرت

شبیه‌سازی شده است. در انتها این نتایج از نظر دقت و زمان اجرا مورد ارزیابی قرار گرفته است.

اگر برای شناسایی غواص تنها از پارامتر قدرت هدف استفاده شود احتمال خطا بسیار بالا می‌رود چرا که قدرت هدف غواص وابسته به زاویه‌ای است که سونار آن را مورد تابش قرار می‌دهد و در زوایای مختلف قدرت هدف غواص و انواع ماهی‌ها ممکن است برابر باشند. در اینجا برای حل این مسأله با استفاده از الگوریتم‌های کلاس‌بندی و همچنین دو پارامتر قدرت هدف و سرعت، تفکیک و کلاس‌بندی این اهداف انجام شده است. در واقع استفاده از دو ویژگی، موجب گسترده‌تر شدن داده‌ها و دقیق‌تر شدن عملیات تفکیک در مقایسه با زمانی است که تنها از یک ویژگی یا همان قدرت هدف بهره گرفته می‌شود [۳].

در ادامه و در بخش دوم مقاله نکاتی در مورد ویژگی‌های قدرت هدف و سرعت غواص و ماهی بیان شده و سپس در قسمت سوم مقدمه‌ای در مورد ماشین بردار پشتیبان و شبکه عصبی ذکر شده است. در بخش چهارم مفاهیم اولیه‌ای چون مدل مخلوطی گوسی و توابع کرنل که در تولید داده و کلاس‌بندی مورد استفاده قرار می‌گیرند بیان شده و پس از آن در قسمت پنجم شبیه‌سازی‌های صورت گرفته برای کلاس‌بندی اهداف با توابع کرنل متفاوت ماشین بردار پشتیبان و شبکه‌های عصبی MLP⁴ و RBF آورده شده است و همچنین نتایج کلاس‌بندی با این الگوریتم‌ها از نظر سرعت و دقت مقایسه شده است؛ بخش ششم مقاله به بیان نتیجه‌گیری اختصاص داده شده است.

ویژگی‌ها

قدرت هدف

قدرت هدف را می‌توان به صورت نسبت شدت صوت بازگشتی به شدت صوت برخوردی به هدف در فاصله ۱ متری از مرکز آکوستیکی آن تعریف کرد. با این اوصاف داریم [۴]:


$$TS = 10 \log \left(\frac{I_r}{I_i} \right) \quad (1)$$

فرمول (۱) قدرت هدف را در واحد دسی‌بل بیان می‌کند. قدرت هدف تعیین کننده امکان استفاده از سونار فعال برای تشخیص غواص است. برای محاسبه پارامتر قدرت هدف غواص، بدن غواص با یک استوانه با طول محدود مدل می‌شود [۶] [۵]؛ استوانه‌ای با طول محدود می‌تواند مدلی مناسب برای شبیه‌سازی بدن غواص باشد که فرمول آن در سه مدل [۷] Urick، [۸] Stanton و [۹] Ganaurd مورد بررسی قرار گرفته است که در این مقاله از مدل اول استفاده شده است. فرمول قدرت هدف استوانه‌ای با طول محدود، در واحد دسی‌بل به صورت زیر است [۵]:

4. Multilayer Perceptron (MLP)

شبکه عصبی پرسپترون چندلایه


شبکه‌های عصبی پرسپترون چندلایه از یک لایه ورودی، یک یا بیشتر لایه مخفی و یک لایه خروجی تشکیل شده‌اند. سیگنال‌های ورودی در حین حرکت از یک لایه به لایه دیگر، از میان شبکه در جهت مستقیم انتشار می‌یابند. آموزش پرسپترون‌های چند لایه به صورت با نظارت و با استفاده از الگوریتم شناخته شده پس انتشار خطا صورت می‌گیرد و می‌توان برای حل مسائل مختلف از این شبکه‌ها استفاده کرد [۲۰][۱۹]. شکل (۳) ساختار گرافی یک شبکه پرسپترون چند لایه را نشان می‌دهد.



شکل ۳. ساختار گرافی یک شبکه پرسپترون [۱۹]

شبکه عصبی تابع پایه شعاعی

یک شبکه عصبی تابع پایه شعاعی از سه لایه: ورودی، مخفی و خروجی تشکیل شده است؛ لایه ورودی در این شبکه از گره‌های ورودی ساخته شده و لایه دوم آن که یک لایه مخفی با ابعاد بالا می‌باشد دارای وظیفه متفاوتی با لایه مخفی در پرسپترون چندلایه است؛ لایه خروجی آخرین لایه در این شبکه است. تبدیل از فضای ورودی به فضای لایه مخفی غیر خطی است، در حالی که تبدیل از فضای لایه مخفی به لایه خروجی خطی است. این شبکه برای جداسازی کلاس‌هایی که به صورت خطی قابل تفکیک نیستند مورد استفاده قرار می‌گیرد [۱۹]. شکل (۴) یک ساختار شبکه RBF را نشان می‌دهد.



شکل ۴. ساختار شبکه عصبی تابع پایه شعاعی [۱۹]

هدف و شدت اکوی بازگشتی بیشتر خواهد بود و در واقع با تبدیل اطلاعات آکوستیکی می‌توان حجم توده‌ی ماهی را تخمین زد [۱۳][۱۲].

قدرت هدف یک ماهی که تابعی از طول ماهی و عمق شنای آن می‌باشد را می‌توان در واحد دسی‌بل از فرمول زیر محاسبه کرد [۱۳]:

$$TS = 20\text{Log}L_t - (20/3)\text{Log}(1+z/10) - 67/6 \quad (5)$$

در فرمول (۵) L_t طول ماهی بر حسب سانتی‌متر و Z عمق شنای ماهی بر حسب متر است.

سرعت

میانگین سرعت شنای انسان ۲ متر بر ثانیه در نظر گرفته شده است؛ ولی برای انواع مختلف ماهی، سرعت شنا به پارامترهایی چون شکل و طول آن وابسته است و می‌توان گفت طول ماهی نسبت مستقیم با سرعت آن دارد [۱۶][۱۵].

الگوریتم‌های کلاس‌بندی

ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از جدیدترین روش‌های مورد استفاده در مسائل کلاس‌بندی اهداف است، این الگوریتم، جزء روش‌های تشخیص الگو دسته‌بندی می‌شود که می‌توان از آن در مسائلی که نیاز به تشخیص الگو یا دسته‌بندی اشیاء در کلاس‌های خاص باشد استفاده کرد. ایده استفاده از این روش برای اولین بار توسط واپنیک^۵ در سال ۱۹۹۸ ارائه شد [۱۷] و بارجس^۶ در همان سال از این ایده به منظور شناسایی الگوها استفاده کرد [۱۸].

شبکه عصبی

طراحی شبکه‌های عصبی الهام گرفته از سیستم عصبی بدن انسان می‌باشد؛ در واقع این شبکه‌ها مانند شبکه عصبی بدن از چندین نرون تشکیل شده‌اند که هر کدام از این نرون‌ها با نرون‌های دیگر در ارتباط می‌باشند. البته لازم به ذکر است که ارتباط بین نرون‌های شبکه عصبی یک ارتباط وزن‌دار می‌باشد که این وزن‌ها پارامترهای مهمی برای آموزش شبکه شناخته می‌شوند. آموزش شبکه عصبی طوری انجام می‌شود که یک ورودی خاص، خروجی خاصی را در لایه‌ی خروجی شبکه ایجاد کند. امروزه می‌توان از شبکه‌های عصبی برای حل مسائل دشواری که برای انسان و کامپیوترهای معمولی پیچیده و سخت هستند، استفاده کرد [۱۹].

5.V. Vapnik
6.C.J.C. Burges

مفاهیم اولیه

مدل مخلوطی گوسی^۷

توابع کرنل متداول در جدول (۱) ذکر شده است [۲۴][۲۳].

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

این مدل برای تولید داده‌هایی با توزیع گوسی و با میانگین و واریانس مشخص برای مسائل کلاس‌بندی مورد استفاده قرار می‌گیرد.

در این مقاله برای تولید داده‌های تست از روی داده‌های آموزشی، از این مدل استفاده شده است. برای این منظور ابتدا میانگین و واریانس دو کلاس داده‌های آموزشی استخراج شده و سپس تعداد ۱۰۰ داده تست برای آزمایش به این روش تولید می‌شود. مدل مخلوطی کلی را می‌توان بصورت زیر نشان داد [۲۱]:

$$F_k(x) = \sum_{k=1}^K c_k f_k(x) \quad (6)$$

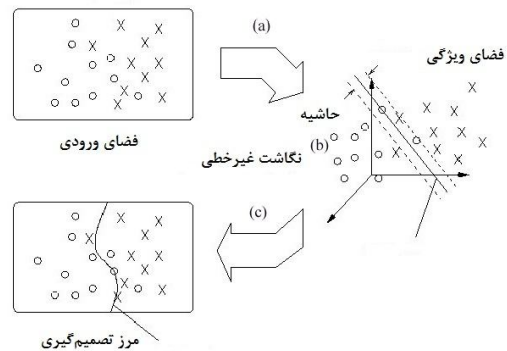
جایی که $\sum_{k=1}^K c_k = 1$ و $c_k \geq 0$ است. K تعداد مولفه‌های مخلوطی، x یک بردار داده ورودی، c_k ضریب وزن، $F_k(x)$ نمایانگر تابع توزیع K امین مولفه مخلوطی و $F_k(x)$ تابع توزیع نهایی ناشی از K توزیع مخلوطی است.

توابع کرنل

در ماشین بردار پشتیبان برای مسائلی که یک ابرصفحه تصمیم‌گیری غیر خطی دارند، یک تابع نگاشت $\phi(x)$ برای انتقال داده‌های اصلی به یک فضای ویژگی با ابعاد بالاتر استفاده می‌شود. ما می‌توانیم 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 کنیم [۲۲].

$$k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (7)$$

تابع k یک کرنل نامیده می‌شود. شکل (۵) عملکرد یک تابع کرنل را در نگاشت داده‌های ورودی به یک فضای ویژگی و انجام عملیات کلاس‌بندی نشان می‌دهد.



شکل ۵. نمایش نقش کرنل در یک مساله کلاس‌بندی [۲۲]


شبیه‌سازی

تولید داده آموزشی


اولین مرحله برای انجام شبیه‌سازی در روش ماشین بردار پشتیبان تولید داده‌های آموزشی است. همانطور که قبلاً ذکر شد کار کلاس‌بندی بر مبنای دو ویژگی سرعت و قدرت هدف انجام شده است. برای هر هدف تعداد ۱۰ داده آموزشی انتخاب شده است که برای تولید آنها طبق روش گفته شده در [۳] عمل می‌شود. در واقع برای تولید داده‌های آموزشی غواص، ۱۰ نقطه به تصادف بر روی محور افقی شکل (۲) به عنوان مدلی از غواص انتخاب و برای این نقاط مقدار قدرت هدف و سرعت محاسبه شده است. لازم به ذکر است که سرعت حرکت غواص به سمت سونار برای این نقاط، مؤلفه‌ی افقی سرعت غواص می‌باشد. داده‌های آموزشی مربوط به ماهی نیز از انتخاب ۱۰ نوع ماهی متفاوت به دست آمده است.

تولید داده‌های مصنوعی

برای بررسی عملکرد روش ماشین بردار پشتیبان پس از تولید و کلاس‌بندی داده‌های آموزشی، باید یک سری داده‌ی مصنوعی براساس آنها ساخت و عملکرد این روش در کلاس‌بندی را بوسیله آنها مورد ارزیابی قرار داد. برای تولید داده‌های مصنوعی غواص، ابتدا ۱۰۰ نقطه (زاویه) به تصادف روی محور افقی شکل (۲) انتخاب شده و سپس قدرت هدف و سرعت معادل این نقاط محاسبه شده است. ولی برای ماهی‌ها بر اساس میانگین و واریانس داده‌های آموزشی و به کمک مدل مخلوطی گوسی، تعداد ۱۰۰ داده تست با توزیع گوسی تولید شده است. در واقع از آنجا که اکثر پدیده‌های طبیعی دارای توزیع گوسی هستند و حرکت ماهی نیز بسته به اینکه مثلاً در حال فرار، شنای عادی و ... باشد، یک متغیر تصادفی است، لذا برای تولید داده‌های مصنوعی از این مدل استفاده شده است.




شکل ۹. کلاس بندی داده های مصنوعی با تابع کرنل Polynomial




شکل ۱۰. کلاس بندی داده های مصنوعی با تابع کرنل Quadratic

نتایج شبیه سازی با روش شبکه عصبی

در این مرحله با استفاده از دو شبکه عصبی پرسپترون چند لایه و شبکه عصبی تابع پایه شعاعی شبکه را آموزش داده و داده های آموزشی و تست را کلاس بندی می کنیم. در شبکه پرسپترون چند لایه از یک لایه مخفی که دارای ۹ نرون است، استفاده شده است. در تمام شکل های (۱۱) تا (۱۵)، محور افقی و عمودی به ترتیب بیانگر اندیس یا شماره داده ها و مقدار نرمالیزه شده ی داده ها هستند.



شکل ۱۱. کلاس بندی داده های آموزشی با شبکه عصبی RBF




شکل ۱۲. کلاس بندی داده های مصنوعی با شبکه عصبی RBF

هدف در این مساله کلاس بندی این داده ها در کلاس مورد نظر و بررسی و مقایسه عملکرد روش های کلاس بندی مورد استفاده می باشد.


نتایج شبیه سازی با روش ماشین بردار پشتیبان

دستورهای Svmtrain و Svmclassify در متلب به ترتیب برای آموزش باینری و کلاس بندی وجود دارند. در شکل (۶) کلاس بندی داده های آموزشی با استفاده از تابع کرنل RBF نشان داده شده است.




شکل ۶. کلاس بندی داده های آموزشی با تابع کرنل RBF

در شکل های زیر نتیجه کلاس بندی داده های مصنوعی با روش ماشین بردار پشتیبان و با توابع کرنل مختلف نشان داده شده است.



شکل ۷. کلاس بندی داده های مصنوعی با تابع کرنل RBF



شکل ۸. کلاس بندی داده های مصنوعی با تابع کرنل Linear


جدول ۲. نتایج میانگین مربعات خطا و سرعت اجرای الگوریتم‌های کلاس‌بندی

زمان اجرا (ثانیه)	میانگین مربعات خطای داده تست	الگوریتم کلاس‌بندی
۰/۰۳۹۳	۰/۰۳	تابع کرنل RBF
۱/۵۹۵۵	۰/۱۰۵	تابع کرنل Linear
۰/۱۴۹۵	۰/۰۹	تابع کرنل Polynomial
۰/۰۳۵۱	۰/۱۲۵	تابع کرنل Quadratic
۰/۶۷۰۴	۰/۲۲۶۰	شبکه پرسپترون چند لایه
۱/۲۱۷۴	۰/۴۲۰۱	شبکه تابع پایه شعاعی


همانطور که نتایج جدول (۲) نشان می‌دهد، الگوریتم ماشین بردار پشتیبان با تابع کرنل RBF از دقت بیشتری برای شناسایی غواص برخوردار است ولی سرعت اجرای الگوریتم ماشین بردار پشتیبان با تابع کرنل Quadratic بیشتر است. با توجه به مصالحه‌ای که بین سرعت و دقت می‌توان برقرار کرد نتیجه گرفته می‌شود که روش ماشین بردار پشتیبان با تابع کرنل RBF برای انجام این کار به صرفه‌تر است.

نتیجه‌گیری

شناسایی غواص از مباحث مهم در حوزه‌ی پدافند دریایی است که یکی از روش‌های مناسب برای انجام این کار استفاده از سونار فعال می‌باشد. در این روش از پارامتر قدرت هدف برای شناسایی بهره گرفته می‌شود. در این مقاله برای شناسایی غواص از دو الگوریتم کلاس‌بندی ماشین بردار پشتیبان و شبکه عصبی استفاده شده است. اهداف مورد نظر، یعنی غواص و ماهی براساس ویژگی‌های قدرت هدف و سرعت کلاس‌بندی شده‌اند. عملیات کلاس‌بندی بوسیله توابع کرنل مختلف ماشین بردار پشتیبان و همچنین شبکه‌های عصبی RBF و MLP انجام و نتایج، بوسیله نرم‌افزار متلب شبیه‌سازی شده‌اند و در انتها تمام این نتایج براساس پارامترهای دقت و سرعت اجرا مورد ارزیابی قرار گرفته‌اند؛ طبق نتایج حاصله، ماشین بردار پشتیبان با تابع کرنل RBF بهترین نتیجه را برای شناسایی غواص در اختیار قرار می‌دهد.




شکل ۱۳. کلاس‌بندی داده‌های آموزشی با شبکه عصبی MLP



شکل ۱۴. کلاس‌بندی داده‌های مصنوعی با شبکه عصبی MLP

برای وضوح بیشتر قسمتی از شکل بالا در حالت بزرگنمایی نشان داده شده است.



شکل ۱۵. کلاس‌بندی داده‌های مصنوعی با شبکه عصبی MLP

مرحله ارزیابی

برای ارزیابی عملکرد الگوریتم‌های کلاس‌بندی دو پارامتر سرعت و دقت مد نظر قرار گرفته است. در واقع در اینجا از پارامتر میانگین مربعات خطا به عنوان معیاری برای میزان دقت الگوریتم‌ها استفاده شده است. نتایج به دست آمده در جدول (۲) نشان داده شده است.

- [1] R. P. Hodges, "Underwater Acoustics Analysis Design and Performance of Sonar," John Wiley, united kingdom, vol. 1, pp. 1-30, 2010.
- [2] M. A. Brinkman, "Tracking and Classification of Divers in Sonar Images," University of OSLO Department of Physics, 2010.
- [۳] علی شعبانی، مرتضی حاجی محمدی و سید محمد علوی، "بهبود دقت شناسایی غواص با استفاده از الگوریتم کلاس‌بندی ماشین بردار پشتیبان،" اولین همایش فناوری‌های نوین دریایی، دانشگاه علوم دریایی امام خمینی نوشهر، ۱۳۹۲.
- [4] A.D. Wait, "Sonar for Practicing Engineers," John Wiley & Sons, England, vol. 3, pp. 60-80, 2002.
- [5] S. Sarangapani, J. H. Miller, G. R. Potty, D. B. Reeder, T. K. Stanton and D. Chu, "Measurements and Modeling of the Target Strength of Divers," Oceans 2005 – Europe, Rhode Island Univ., Narragansett, RI, USA vol. 2, pp. 952-956, 2005.
- [۶] علی شعبانی و سید محمد علوی، "مدل‌سازی و شناسایی غواص با استفاده از پارامتر قدرت هدف،" دومین همایش سراسری فناوری سیستم‌های راداری، دانشگاه جامع امام حسین(ع)، ۱۳۹۱.
- [7] R.J. Urick, "Principles of Underwater Sound," McGraw – Hill Book company, New York, vol. 3, pp. 295-320, 1970.
- [8] T. K. Stanton, "Sound Scattering by Cylinders of Finite Length. I. Fluid Cylinders," J. Acoust. Soc. Am, vol. 83, pp. 64-67, 1988.
- [9] G. C. Gaunaud, "Sonar Cross Sections of Bodies Partially Insonified by Finite Sound Beams", IEEE J. Ocean. Eng, vol. 10, pp. 213-230, 1985.
- [10] D.E. Kerr, "Propagation of Short Radio Waves", M.I.T. Radiation Laboratory series, McGraw – Hill Book Company, New York, vol. 1, pp. 445-469, 1951.
- [۱۱] علی شعبانی و سید محمد علوی، "ارائه روشی جدید برای محاسبه پارامترهای قدرت هدف اجزاء تشکیل دهنده‌ی بدن غواص،" مجله علمی-پژوهشی پدافند غیرعامل، سال چهارم، شماره ۴، ص ۲۷۰-۲۶۵، ۱۳۹۲.
- [12] G. Pederse, O. Run God, E. Ona and G.j. Macaulay, "A Revised Target Strength-Length Estimate For Blue Whiting: Implication For Biomass Estimate,s" ICES Journal of Marie Science, vol. 68(10), pp. 2222-2228, 2011.
- [13] H. Murase, K. Abe, K. Miyashita and Y. Oozeki, "Effect Of Depth-Dependevt Target Strength On Biomass Estimation Of Japanese Anchovy," Journal of marine science and technology, vol. 19, pp. 267-272, 2011.
- [14] T. Iwai, M. Hisada, "Fishes - Illustrated Book of Gakken (in Japanese)," Gakken, 1998.
- [15] H. Nagai, "Fluiddynamics Learned from Dolphin (in Japanese)," Ohm Books, 1999.
- [16] V. Vapnik, A. Lerner, "Pattern recognition using generalized portrait method," Automation and Remote Control, vol. 24, pp. 774-780, 1963.
- [17] C.J.C. Burges, "A Tutorial on Support Vector Machines For Pattern Recognition", Data Mining and Knowledge Discovery, vol. 2, pp. 121-167, 1998.
- [18] J. Sima, "Introduction to Neural Networks," Technical report, Institute of Computer Science, Academy of Sciences of the Czech Republic, No.V-755, Aug 10, 1998.
- [19] 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.
- [20] R. Balada, "Radar Signal Recognition Method Based On Gaussian Mixture Models," Doctoral Degree Programme, Fec But.
- [21] J. Solomon, "Sepport Vector Machines For Phoneme Classification," Master Of Science, Schools Of Artificial Intelengce Division Of Informatics University Of Edinburg, 2001.
- [22] P. Watanac haturaporn, 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.
- [23] Lee, M. C., Chang To., "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.

