

طبقه‌بندی سیگنال‌های سونار غیرفعال با استفاده از ادغام ویژگی‌های طنین صوت و تبدیل فوریه زمان-کوتاه

وحید باقری^۱، احمد کشاورز^۲، حبیب رستمی^۳

habib@pgu.ac.ir

۱- دانشجوی کارشناسی ارشد دانشکده فنی و مهندسی، دانشگاه خلیج فارس

۲- استادیار دانشکده فنی و مهندسی، دانشگاه خلیج فارس

۳- استادیار دانشکده فنی و مهندسی، دانشگاه خلیج فارس

چکیده

تشخیص و طبقه‌بندی شناورهای دریایی بر اساس نویز تشعشعی صوتی از آن‌ها از جمله ضرورت‌های سیستم‌های سوناری است. در این مقاله روش‌هایی که تاکنون در حوزه طراحی سیستم طبقه‌بندی اهداف سونار غیرفعال انجام شده است مورد بررسی قرار گرفته و الگوریتمی جدید ارائه گردیده است. در روش پیشنهادی با استفاده از الگوریتم استخراج ویژگی تحلیل تفکیک کننده خطی (LDA) و ترکیب ویژگی‌های تبدیل فوریه زمان کوتاه (STFT) و طنین صوت، الگوریتم طبقه‌بندی با نام STFTLDA-Timb ارائه شده است که موجب استخراج ویژگی‌هایی با تفکیک پذیری بالا شده و صحت طبقه‌بندی را در مقایسه با سیستم‌های متداول مبتنی بر تبدیل فوریه زمان-کوتاه تا ۸/۴۵٪ بهبود بخشیده است. الگوریتم پیشنهادی بر روی برخی داده‌های واقعی آزمایش شده و نتایج حاصل شده در مقایسه با الگوریتم‌های طبقه‌بندی کننده رایج و پرکاربرد مثل طبقه‌بندی کننده‌های آماری، طبقه‌بندی کننده‌های شبکه عصبی و طبقه‌بندی کننده‌های تجمعی، نتایج بهتری را ارائه کرده است.

واژگان کلیدی: سونار، طبقه‌بندی، ادغام ویژگی، فوریه زمان-کوتاه، طنین صوت.

تاریخ دریافت مقاله :	۹۶/۰۶/۰۹
تاریخ پذیرش مقاله :	۹۷/۰۲/۲۶

۱- مقدمه

توانایی تشخیص و طبقه‌بندی سیگنال‌های صوتی ساطع شده از اهداف مختلف، مهمترین چالش نیرو دریایی کشورها در شرایط جنگ دریایی محسوب می‌شود. هنوز هم در اغلب مواقع کشف و دسته‌بندی اهداف زیر آب توسط اپراتورهای سونار انجام می‌شود. در این روش کاربران وظیفه دارند به وسیله مشاهده اطلاعات تصویری حاصل شده از طیف نگاره و شنیدن دقیق صدای به دست آمده از هدف، نسبت به تشخیص نوع هدف تصمیم‌گیری کنند. این وظیفه، فشار کاری بسیار سنگینی به این کاربران تحمیل می‌کند. از اینرو طراحی سیستمی خودکار برای طبقه‌بندی اهداف سونار غیرفعال به منظور کاهش بار کاری کاربران سونار امری ضروری و با اهمیت به شمار می‌رود [۱]. در سال‌های اخیر استفاده از پردازش‌های حوزه زمان-فرکانس به عنوان روش‌هایی موثر در حذف نویز و استخراج ویژگی‌های متمایز کننده، مورد توجه خاصی قرار گرفته است. استفاده از تبدیل فوریه زمان-کوتاه^۱ (STFT) [۲ و ۳] و تبدیل موجک [۴-۷] از این قبیل روش‌ها می‌باشند. در [۲] الگوریتمی برای طبقه‌بندی اهداف سونار غیرفعال ارائه شده است که بر مبنای تبدیل فوریه زمان-کوتاه (STFT) به عنوان ویژگی‌ها و شبکه عصبی پاسخ ضربه محدود به عنوان طبقه‌بندی کننده است.

استخراج ویژگی مناسب از سیگنال‌های سونار تاثیر زیادی بر صحت نهایی طبقه بندی دارد. به منظور بهبود ویژگی‌های استخراجی، الگوریتم‌های مختلفی ارائه شده است. در [۸] از الگوریتم تحلیل مولفه‌های اصلی^۲ به منظور استخراج ویژگی از سیگنال‌های سونار غیرفعال استفاده شده است. در [۹] از نظریه آشوب^۳ برای استخراج ویژگی از سیگنال‌های سونار استفاده شده است. در [۱۰] تلاش شده است با استخراج ویژگی‌های غیرخطی، صحت نهایی طبقه بندی بهبود یابد. در [۱۱] نویز آکوستیکی کشتی به وسیله یک مدل خودبرگشتی استخراج شده، و ضرایب این مدل برای طبقه‌بندی کشتی‌ها استفاده شده است. در [۱۲] جهت دستیابی به ویژگی‌های با تفکیک‌پذیری بالا از روش تبدیل فوریه زمان-کوتاه و تصحیح نویز^۴ TPSW و یکه کردن

طیف فرکانسی استفاده شده است. در این مقاله طبقه‌بندی سیگنال‌های سونار غیرفعال با تنظیم های مختلف پارامترهای این روش مورد ارزیابی قرار گرفته است. در [۱۳] روشی برای تشخیص اهداف زیر آب با استفاده از الگوریتم تبدیل موجک و ماشین بردار پشتیبان بر پایه ادراک شنوایی ارائه گردیده است.

علاوه بر ویژگی‌های استخراجی از سیگنال سونار، طبقه‌بندی کننده نیز تاثیر زیادی در صحت کلی الگوریتم دارد. در مقاله‌های بسیاری از شبکه عصبی برای طبقه‌بندی سیگنال‌های سونار استفاده شده است [۱۴-۱۷]. در [۱۸] از روش‌های پردازش زمان-فرکانس که بر مبنای تبدیل فوریه کسری زمان-کوتاه می‌باشد، برای دستیابی به ویژگی‌های با تفکیک‌پذیری مناسب استفاده شده است. در این مقاله با استفاده از ویژگی‌های استخراج شده، پنج دسته شناور مختلف با طبقه بندی کننده شبکه عصبی تابع پایه شعاعی^۵ RBF دسته‌بندی شده است. در این روش با تغییر مرتبه تبدیل فوریه کسری (a) در بازه ۰ تا ۱ با گام‌های ۰/۱ عملکرد سیستم طبقه‌بندی مورد ارزیابی قرار گرفته که به ازای مرتبه کسر $a=0/96$ بهترین عملکرد سیستم طبقه‌بندی به دست آمده است. از مزایای تبدیل فوریه کسری زمان-کوتاه اختصاص مرتبه کسری a است که می‌تواند با چرخش سیگنال در صفحه زمان-فرکانس، نمایش بهینه‌ای از سیگنال به منظور استخراج ویژگی‌های بهتر ارائه دهد. در الگوریتم ارائه شده، انتخاب مرتبه کسری تاثیر بسیار مهمی در نتیجه نهایی سیستم طبقه بندی دارد و نبود یک الگوریتم مناسب در پیدا کردن مرتبه کسری بهینه از معایب این روش به شمار می‌آید.

در [۱۹] از روش بهینه‌سازی گرگ خاکستری^۶ (GWO) که توانایی بالایی در حل مسائل ابعاد بالا دارد برای آموزش شبکه‌های عصبی به منظور طبقه‌بندی داده‌های سونار استفاده شده است. این روش به علت سرعت همگرایی در به دام انداختن مینم‌های محلی و دقت طبقه‌بندی عملکرد مناسب‌تری نسبت به الگوریتم‌های جستجوی گرانشی^۷ (GSA) و ازدحام ذرات^۸ (PSO) ارائه داده است. در [۲۰] به دلیل قابلیت AGPSO در حل مسائل با ابعاد بالا، از ترکیب

⁵ Radial Basis Function⁶ Gray Wolf Optimization⁷ Gravitational Search Algorithm⁸ Particle Swarm Optimization¹ Short-Time Fourier Transform² Principle Component Analysis³ Chaos⁴ Two Pass Split Window

طبقه‌بندی‌کننده می‌گردند. در این مقاله سیستم طبقه‌بندی هوشمندی بر مبنای ترکیب تبدیل فوریه زمان-کوتاه و ویژگی‌های طنین صوت ارائه شده است. به طور کلی برای بهبود بازدهی یک سیستم طبقه‌بندی می‌توان به دو روش عمل کرد: ۱- استخراج ویژگی‌هایی با تفکیک‌پذیری بالاتر ۲- استفاده از طبقه‌بندی‌کننده کارآمدتر. البته استفاده همزمان هر دو روش نیز موثر خواهد بود. در این تحقیق با تمرکز روی هر دو روش سعی شده است تا عملکرد سیستم طبقه‌بندی افزایش داده شود. در واقع با استفاده از ترکیب طبقه‌بندی‌کننده‌های مختلف با الگوریتم رای اکثریت، یک مدل طبقه‌بندی‌کننده با قابلیت اعتماد مناسب ارائه شده است. در ادامه در بخش ۲ داده‌های مورد استفاده در این تحقیق معرفی شده است. سپس در بخش ۳ قسمت‌های مختلف الگوریتم پیشنهادی بررسی شده است. بخش ۴ نتایج آزمایش‌های مختلف بررسی شده و در بخش ۵ نتیجه‌گیری انجام شده است.

۲- داده‌های مورد استفاده

در این تحقیق از داده‌های واقعی جمع‌آوری شده از ۵ دسته مختلف شناور سطحی استفاده شده است. سیگنال‌ها با استفاده از هیدروفون همه‌جهته بویه‌ای که در فاصله ۲ کیلومتری از ساحل و عمق ۱۸ متری از آب قرار گرفته، دریافت شده است. حداکثر فاصله شناورها از بویه تقریباً ۲۰۰ متر بوده است. داده‌ها با مبدل آنالوگ به دیجیتال ۸ بیتی و با فرکانس نمونه برداری ۲۲۰۵۰ هرتز نمونه برداری شده‌اند. جدول ۱ جزئیات مربوط به تعداد رکوردها را به تفکیک هر دسته و مدت زمان آن‌ها نشان می‌دهد. برای انجام آزمایش‌های مختلف، هر رکورد به چند زیربازه زمانی تقسیم شده است. با توجه به توضیحات ارائه شده در بخش ۱-۳ اندازه هر زیربازه در حدود ۲۷۸ میلی‌ثانیه در نظر گرفته شده است. به این ترتیب تعداد نمونه‌های شناورهای یک تا پنج به ترتیب برابر با ۲۷۹۰، ۲۷۸۱، ۲۷۳۰، ۲۶۸۸ و ۱۳۸۳ نمونه است.

۳- روش ارائه شده

با توجه به اینکه تبدیل فوریه زمان کوتاه (STFT) از

روش AGPSO^۱ و FFNNs^۲ برای دسته‌بندی داده‌های شناور استفاده شده است. نتایج الگوریتم پیشنهادی این مقاله با روش PSO استاندارد، PSO اصلاح شده، الگوریتم GSA و GWO مقایسه شده که عملکرد بهتری را نسبت به روش‌های ذکر شده در سرعت همگرایی، دقت طبقه‌بندی و فرارگیری در کمینه محلی نشان داده است. در [۲۱ و ۲۲] از الگوریتم بهینه‌سازی بر مبنای بیوجغرافیایی^۳ (BBO) با آشوب (CBBO)، جهت آموزش شبکه عصبی چند لایه پرسپترون برای طبقه‌بندی داده‌های شناور بهره گرفته شده است. نتایج نشان داده است که الگوریتم جدید نتیجه بهتر و قابل قیاس‌تری در همه حالت‌ها در مقایسه با روش‌های اکتشافی^۴ و متا اکتشافی دارد. این روش عملکرد بهتری را از نظر سرعت همگرایی، دقت دسته‌بندی و جلوگیری از فرارگیری در کمینه محلی، نسبت به دیگر الگوریتم‌های معمول ارائه کرده است.

در دهه‌های گذشته کارهای زیادی در زمینه ارائه یک نمایش زمان-فرکانس مناسب جهت نمایش ساده‌تر سیگنال‌های صوتی و استخراج ویژگی مؤثر جهت طبقه‌بندی سیگنال‌ها در شناور غیرفعال ارائه شده است. معروفترین و پرکاربردترین آنها سیستم طبقه‌بندی بر مبنای تبدیل فوریه زمان-کوتاه می‌باشد.

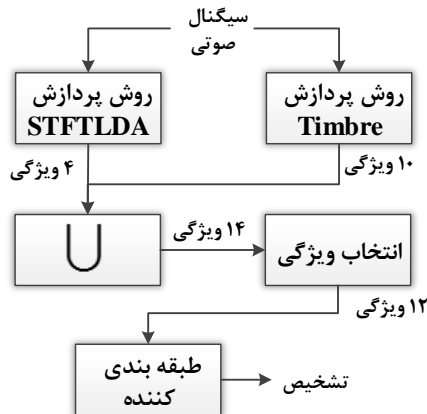
STFT می‌تواند برخی ویژگی‌های حوزه زمان را به خوبی حوزه فرکانس تجزیه و تحلیل کند. اما این الگوریتم گزینه مناسبی برای تحلیل سیگنال‌های گذرا نیست. علاوه بر این، برای همه ویژگی‌ها در خروجی خود (بین‌های فرکانسی) ارزش یکسانی قائل است. بنابراین ممکن است محتوای اطلاعاتی برخی از ویژگی‌ها مفید نباشد و باعث بالا رفتن نرخ خطا در سیستم طبقه‌بندی‌کننده شود. در این مقاله تکنیک‌های استخراج ویژگی برای بهبود روش STFT و دستیابی به ویژگی‌های با تفکیک‌پذیری بالاتر ارائه شده است. علاوه بر این برای در نظر گرفتن مولفه‌های غیرایستنا سیگنال در طبقه‌بندی، از ویژگی‌های فیزیکی سیگنال (ویژگی‌های طنین صوت) که پیشتر در حوزه شناور غیرفعال به کار گرفته نشده بود، استفاده شده است. ترکیب این ویژگی‌های جدید طیفی و زمانی علاوه بر ایجاد تفکیک‌پذیری قابل توجه، موجب تسهیل در ساختن مدل

³ Biogeography-based Optimizer

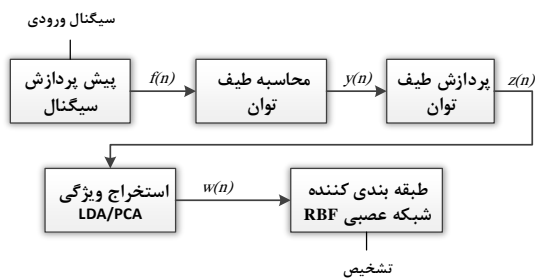
⁴ Heuristic Algorithm

¹ Particle Swarm Optimizer with Autonomous Groups


² Feed-Forward Neural Networks



شکل (۱) ساختار کلی الگوریتم پیشنهادی با استفاده از ویژگی های STFTLDA-Timbre.



شکل (۲) بلوک دیاگرام استخراج ویژگی های طیفی STFT.



شکل (۳) عملیات پیش پردازش بر روی سیگنال های ورودی.

۳-۲- پیش پردازش سیگنال

با استفاده از تحلیل های انجام شده بر روی سیگنال های سونار ناشی از کشتی ها، مشخص شد که عمده اطلاعات طیفی مفید در فرکانس های کمتر از سه کیلوهرتز قرار گرفته است [۲۳]. جهت تمرکز بر محدوده صحیح فرکانسی سیگنال سونار غیرفعال، از بلوک دیاگرام شکل ۳ استفاده شده است.

در مرحله نخست، سیگنال فیلتر شده و نرخ نمونه برداری سیگنال کم می شود تا اینکه فرکانس نمونه برداری به مقدار ۷۳۵۰ هرتز کاهش یابد. فیلتر مورد استفاده در اینجا، یک فیلتر چیبشف^۱ پائین گذر مرتبه هشتم از نوع یک با فرکانس قطع برابر با ۲/۸۷ کیلو هرتز می باشد که دارای تضعیف سیگنال در ناحیه گذر به میزان ۷۲ دسی بل است. این فیلتر تضمین می نماید که پس از فرآیند کاهش نرخ نمونه برداری، هیچ گونه اثر تداخلی در باند گذر

روش های بسیار کارآمد در طبقه بندی داده های سونار غیرفعال است، سیستم پیشنهادی بر مبنای پردازش زمان-فرکانس STFT قرار گرفته است. اما به دلیل برخی معایب این روش از جمله تعداد زیاد ویژگی ها، از تکنیک های استخراج یا انتخاب ویژگی استفاده می شود.

جدول (۱) جزئیات داده ها.


دسته	تعداد رکورد	طول زمانی هر رکورد (ثانیه)	درصد جمع کل (٪)	تعداد نمونه ها
شناور ۱	۶	۱۳۰	۷۸۰	۲۷۹۰
شناور ۲	۶	۱۲۹	۷۷۴	۲۷۸۱
شناور ۳	۶	۱۲۷	۷۶۲	۲۷۳۰
شناور ۴	۶	۱۲۵	۷۵۰	۲۶۸۸
شناور ۵	۳	۱۲۹	۳۸۴	۱۳۸۳
جمع کل	۲۷	-	۳۴۵۰	۱۲۳۷۲

این الگوریتم ها علاوه بر کاهش ابعاد، و در نتیجه کاهش زمان ساختن مدل طبقه بندی کننده، موجب افزایش صحت طبقه بندی سیستم می گردد. در این مقاله به منظور افزایش ضریب اطمینان طبقه بندی کننده، برای اولین بار در حوزه سونار غیرفعال از ویژگی های طنین صوت که شامل پوش های طیفی و زمانی سیگنال می باشد، استفاده شده است. در مرحله بعد برای دستیابی به یک طبقه بندی کننده با قابلیت اعتماد بالا، چندین طبقه بندی کننده آماری، شبکه های عصبی و تجمعی مورد ارزیابی قرار گرفته و طبقه بندی کننده های با بازدهی بالاتر در الگوریتم نهایی استفاده شده است. در شکل (۱) ساختار کلی الگوریتم پیشنهادی نشان داده شده است. در ادامه بخش های مختلف الگوریتم پیشنهادی بررسی می گردد.


۳-۱- استخراج ویژگی های طیفی STFT

ساختار کلی برای استخراج ویژگی های مطلوب طیفی STFT در شکل (۲) نشان داده شده است. برای دستیابی به ویژگی های بهتر ابتدا باید پیش پردازش مناسبی بر روی سیگنال ها انجام شود. برای این منظور فرکانس های بیشتر از سه کیلو هرتز و نویزهای پس زمینه محیطی حذف شده است [۲۳]. در ادامه بخش های مختلف این بلوک دیاگرام توضیح داده می شود.

^۱ Chebyshev



شکل (۴) محاسبه طیف توان از سیگنال پردازش شده.



شکل (۵) پردازش بر روی طیف حاصل از STFT قبل از اعمال به طبقه‌بندی کننده.

تحلیل‌های انجام شده در مرجع [۱۲] نشان می‌دهد یک ترکیب نسبت به ۲۸۸ ترکیب دیگر، بالاترین صحت طبقه‌بندی را ارائه می‌دهد. این ترکیب متناظر با استفاده از طیف فرکانسی با ۴۰۰ بین (F)، تصحیح نویز پس زمینه لگاریتمی (Y)، عدم استفاده از هیچ یک از روش‌های نرمالیزاسیون طیف (W) و نرمالیزاسیون بین فرکانسی (Z) است. در فرایند تصحیح نویز پس زمینه، در ابتدا با استفاده از روش TPSW [۲۴] نویز پس زمینه موجود در محیط زیرآب تخمین زده می‌شود $m_k(n)$ و سپس با استفاده از رابطه زیر از سیگنال اصلی $x_k(n)$ کم می‌شود.

$$y = \log(x_k(n)) - \log(m_k(n)) \quad (1)$$

۳-۴- استخراج ویژگی LDA/PCA

تحلیل تفکیک خطی LDA [۲۴] یک روش شناخته شده در کاهش ابعاد فضای ویژگی است. LDA یک ترکیب خطی از ویژگی‌ها را محاسبه می‌کند که دو یا چند دسته از اهداف مورد نظر را از یکدیگر تفکیک و توصیف می‌کند. یکی دیگر از الگوریتم‌های رایج استخراج ویژگی، تحلیل مؤلفه‌های اصلی^۲ (PCA) است. الگوریتم PCA ویژگی‌ها را به گونه‌ای استخراج می‌کند که بیشترین انرژی سیگنال توسط آن‌ها منتقل و توصیف شود.

در این مقاله، پس از انجام پردازش‌های اولیه روی داده‌های سونار غیرفعال، در صورتی که از روش استخراج ویژگی LDA استفاده شود روش مذکور را STFTLDA و در

ایجاد نخواهد شد. در ادامه، بلوک‌های متوالی مربوط به ۲۰۴۸ نمونه، بدون همپوشانی، در پنجره هنینگ^۱ ضرب می‌شوند.

برای این منظور پنجره‌هایی با طول ۲۰۴۸ انتخاب شده است و سپس این پنجره‌ها بدون همپوشانی شروع به حرکت از ابتدای سیگنال کرده و به صورت متوالی به سمت راست جا بجا می‌شوند تا به انتهای سیگنال موجود برسد. طول پنجره تاثیر زیادی بر کیفیت ویژگی‌های طیفی استخراج شده دارد. یک پنجره با طول زمانی کوتاه باعث ایجاد دقت زمانی مناسب ولی دقت فرکانسی نامطلوب در صفحه زمان-فرکانس می‌شود. در این جا پهنای پنجره در حدود ۲۷۸ میلی ثانیه (۲۰۴۸ نمونه) انتخاب شده است [۱۸] که این مقدار برای به دست آوردن میانگین زمانی لازم جهت محقق کردن فرض ایستادن بودن سیگنال مناسب است.

۳-۳- محاسبه طیف توان

جهت انتقال سیگنال به حوزه فرکانس و تحلیل طیف توان، از قطعه‌های سیگنال حاصل از پنجره‌های هنینگ، تبدیل فوریه سریع ۲۰۴۸ نقطه ای گرفته می‌شود و سپس طیف توان محاسبه می‌شود (شکل ۴). از هر طیف به دست آمده تعداد ۸۰۰ بین فرکانسی که متناظر با محدوده فرکانسی از مقدار DC تا فرکانس ۲/۸۷ کیلو هرتز است به منظور انجام تحلیل‌های بعدی نگه داشته می‌شوند.

پردازش طیف توان:

در مقاله ارائه شده در [۱۸]، در ارزیابی روش STFT، ۲۸۸ ترکیب از پارامترهای مختلف محاسبه طیف توان بررسی و بازدهی حاصل از هر ترکیب با استفاده از طبقه‌بندی کننده شبکه عصبی ارزیابی شده است. در این مقاله هر طیف با در نظر گرفتن توالی نشان داده شده در شکل ۵، پردازش می‌شود.

بلوک اول که F نام دارد، عرض بین فرکانسی را تعیین می‌کند یکی از مقادیر ۲۰۰، ۴۰۰ و یا ۸۰۰ بین می‌باشد. بلوک دوم (Y)، تصحیح طیف با استفاده از حذف نویز پس زمینه تخمین زده شده را ارائه می‌دهد. بلوک سوم (Z)، به الگوریتم نرمالیزاسیون دامنه هر طیف اختصاص دارد و بلوک چهارم (W)، به الگوریتم نرمالیزاسیون هر بین فرکانسی با استفاده از اطلاعات آماری استخراج شده از مجموعه نمونه‌های آموزشی اختصاص دارد.

²Principal Component Analysis

¹ Hanning Window

STFTPCA و STFTLDA، STFT			
روش	تعداد ویژگی	صحت طبقه بندی (%)	توضیح
STFT	۴۰۰	۹۰٫۳۸	بالاترین بازدهی در این روش
STFTPCA	۵۰	۸۷٫۴۶	-
STFTLDA	۴	۹۲٫۹۶	-

ویژگی و شناسایی الگو مورد توجه قرار می‌گیرد، استفاده از ویژگی‌های ادراکی صوت یا طنین صوت است. این ویژگی‌ها تلفیقی از ویژگی‌های حوزه زمان و فرکانس می‌باشند. طنین، کیفیت صوت است که به گوش انسان این امکان را می‌دهد تا صداهای مختلف را حتی با داشتن دانگ و بلندی یکسان، از یکدیگر تشخیص دهد. تاکنون اغلب کاربردهای این ویژگی‌ها در تشخیص و طبقه‌بندی اصوات موسیقی و دستگاه‌های تولید کننده صوت بوده است. ویژگی‌های طنین، یک روش پردازش حوزه زمان فرکانس را ارائه می‌کنند که برخلاف دیگر روش‌های پردازش زمان-فرکانس، از محتوای اطلاعاتی و ادراکی صوت جهت تفکیک دسته‌ها استفاده می‌کند. این روش برای اولین بار در [۱۹] ارائه شد.

در این مقاله از این ویژگی‌ها جهت تشخیص و طبقه‌بندی سیگنال‌های صوتی تشعشع یافته از شناورهای دریایی در محیط زیر آب استفاده شده است. صداهای تشعشع یافته از شناورهای متفاوت در آب توسط یک اپراتور حرفه‌ای سونار قابل تشخیص و تفکیک است. بنابراین می‌توان ادعا کرد که هر شناور دارای ویژگی‌های طنین منحصر به فرد خود است و ویژگی‌های ادراکی طنین می‌تواند در تفکیک دسته‌های متعدد شناورها از یکدیگر مفید باشند. ویژگی‌های طنین از دو دسته ویژگی مرتبط با هم تشکیل شده است: ویژگی‌های فیزیکی پوش طیف در حوزه فرکانس و ویژگی‌های پوش دامنه در حوزه زمان. ویژگی‌های زیر بر اساس پوش طیفی و پوش زمانی استخراج می‌شوند.

مرکز ثقل طیف (SC^۵): این ویژگی مرکز ثقل طیف و یا میانگین دامنه وزن دهی شده طیف فرکانسی در STFT را بیان می‌کند.

صورتی که از روش استخراج ویژگی PCA استفاده شود، روش مذکور STFTPCA نامیده شده است. به دلیل ماهیت روش استخراج ویژگی LDA، تعداد مؤلفه‌های استخراج شده حداکثر می‌تواند یک عدد از تعداد دسته‌ها کمتر باشد. از آنجایی که در این مقاله از ۵ دسته شناور سطحی استفاده شده است، تعداد ویژگی‌ها در خروجی روش STFTLDA، ۴ عدد می‌باشد. در پیاده سازی الگوریتم STFTPCA جهت تعیین تعداد ویژگی‌های استخراج شده، از روش ارائه شده در [۲۵] استفاده شده است که براساس انتخاب بردارهای ویژه با مقادیر ویژه بزرگتر از میانگین مقادیر ویژه می‌باشد.

$$\lambda_m \geq \frac{1}{n} \sum_{i=1}^n \lambda_i \quad (۲)$$

در این رابطه n تعداد ویژگی‌های اولیه و m تعداد ویژگی‌های استخراج شده است. پس از انجام طبقه‌بندی بر روی داده‌های پردازش شده بازدهی حاصل از هر یک از روش‌های STFTLDA و STFTPCA و STFT معمولی با استفاده از طبقه‌بندی کننده پایه شعاعی، در جدول (۲) آورده شده است.

همان‌طور که مشاهده می‌شود، ویژگی‌هایی که از روش پردازش حوزه زمان-فرکانس STFTLDA استخراج شده است، توانسته است صحت طبقه‌بندی را به صورت محسوسی ارتقاء دهد. این در حالی است که STFTPCA نسبت به STFT معمولی برتری ندارد.

۳-۵- طبقه‌بندی کننده

در این جا از شبکه عصبی تابع پایه شعاعی^۱ (RBF) به عنوان طبقه‌بندی کننده و الگوریتم یادگیری پس انتشار خطا به عنوان الگوریتم آموزش شبکه استفاده شده است. تابع هسته مورد استفاده در شبکه RBF تابع گوسی و معیار خطا، خطای میانگین مربعات^۲ (MSE) است. جهت سنجش اعتبار طبقه‌بندی کننده از اعتبار سنجی تقاطعی ۱۰ لایه ای^۳ استفاده شده است.

۳-۶- ویژگی‌های طنین صوت^۴

یکی از روش‌هایی که در پردازش صوت در حوزه استخراج جدول (۲) مقایسه صحت طبقه‌بندی حاصل از سه روش

^۴ Timbre

^۵ Spectral Centroid

^۱ Radial Basis Function

^۲ Mean Squared Error

^۳ 10-Fold Cross Validation

$$SS = \frac{\sqrt{\sum_{n=0}^{N/2} (N_t(n) - SC)^2}}{\sqrt{\sum_{n=0}^{N/2} (N_t(n))^2}} \quad (۶)$$

انحراف طیف (SK^۸): این ویژگی بیانگر سنجش از میزان عدم تقارن توزیع در اطراف مقدار میانگین است.

$$SK = \frac{\sum_{n=1}^N (N_t(n) - \mu)^3}{N \sigma^3} \quad (۷)$$

که در آن μ میانگین و σ انحراف استاندارد است. مقدار مثبت SK یعنی توزیع طیف دارای دنباله در فرکانس‌های بالاتر و مقدار منفی آن یعنی طیف دارای دنباله در فرکانس‌های پایین‌تر است. مقدار صفر یعنی توزیع متقارن است.

پیک توان (PP^۹): ماکزیمم مقدار توان کل به ازای کلیه پنجره‌های زمانی به عنوان یک ویژگی متمایز کننده سیگنال می‌توان استفاده کرد.

$$PP = \max(P_t) \quad (۸)$$

که P_t توان پنجره t ام است و از معادله زیر به دست می‌آید.

$$P_t = \sum_f P_{t,f} \quad (۹)$$

میانگین توان (AP^{۱۰}): میانگین توان کل بر روی کلیه پنجره‌های زمانی از رابطه زیر به دست می‌آید.

$$AP = \frac{\sum_t P_t}{T} \quad (۱۰)$$

انرژی: انرژی کلی سیگنال $x[n]$ می‌تواند به سادگی با محاسبه میانگین توان دوم دامنه و گرفتن ریشه دوم آن به دست آید که به آن RMS^{۱۱} انرژی مؤثر نیز گفته می‌شود.

$$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (۱۱)$$

که x_i نمونه i ام از فریم t و n تعداد نمونه‌های فریم است. **نرخ عبور از صفر^{۱۲} (ZCR):** نرخ عبور از صفر هر نمونه، تعداد تغییر علامت موج حاصل از عبور سیگنال از فریم زمانی است.

برای محاسبه ZCR می‌توانیم از رابطه زیر استفاده کنیم.

$$C_t = \frac{\sum_{n=1}^N n \cdot |M_t[n]|^2}{\sum_{n=1}^N |M_t[n]|^2} \quad (۳)$$

$M_t[n]$ دامنه تبدیل فوریه فریم t و بین فرکانسی n ام است. **شار طیف (SF^۱):** این ویژگی سنجشی از میزان تغییرات طیف محلی را ارائه می‌کند. این ویژگی با مربع اختلاف بین دامنه‌های نرمالیزه شده دو طیف متوالی بیان می‌شود.

$$F_t = \sum_{n=1}^N (N_t[n] - N_{t-1}[n])^2 \quad (۴)$$

طوری که $N_t[n]$ و $N_{t-1}[n]$ به ترتیب دامنه‌های نرمالیزه شده تبدیل فوریه در فریم زمانی فعلی t و فریم زمانی قبلی $t-1$ است.

همواری طیف (SFlat^۲): همواری طیف که به آنتروپی وینر^۳ هم شناخته شده است، میزان شبه تون بودن صدا را تعیین می‌کند. در مقابل آن معیار میزان شبه نویز بودن صدا وجود دارد. این ویژگی عموماً بر حسب دسی بل (dB) بیان می‌شود. منظور از تونال^۴، میزان پیک‌ها و سبک تشدید در طیف توان است که نقطه مقابل طیف مسطح یک نویز سفید است.

یک طیف با میزان همواری بالا نشان می‌دهد که دارای میزان توان مشابه در کل باند فرکانسی خود است، که این شبیه نویز سفید است. از طرفی یک سیگنال با میزان همواری طیف کم نشان می‌دهد که طیف توان در تعداد کمی از باند فرکانسی متمرکز شده است. این حالت شبیه به این است که سیگنال مخلوطی از موج‌های سینوسی است و در نتیجه شکل طیف در این حالت تند و تیز^۵ و دارای تغییرات شدید است.

همواری طیف (SFlat^۶): با تقسیم کردن میانگین هندسی طیف توان بر میانگین حسابی طیف توان به دست می‌آید.

$$Flatness = \frac{\sqrt[N]{\prod_{n=1}^N M_t[n]}}{\sum_{n=1}^N M_t[n]} \quad (۵)$$

وسعت طیف (SS^۷): این ویژگی سنجشی از پراکندگی طیف در همسایگی مقدار میانگین را ارائه می‌کند.

⁷ Spectral Spread

⁸ Spectral Skewness

⁹ Peak Power

¹⁰ Average power

¹¹ Root-Mean-Square-Energy

¹² Zero Crossing Rate

¹ Spectral Flux


² Spectral Flatness

³ Wiener Entropy


⁴ Tonal

⁵ Spiky

⁶ Spectral Flatness



(الف)



(ب)

شکل (۶) الف) سیگنال صوتی و ب) محاسبه ZCR پوش سیگنال الف.

در مجموع ۱۴ ویژگی به عنوان بردار ویژگی، به طبقه‌بندی-کننده شبکه عصبی RBF اعمال می‌گردد. برای آموزش و ارزیابی شبکه عصبی از روش K-Fold استفاده شده است. در این مقاله K برابر با ۱۰ در نظر گرفته شده است. برای این منظور در ابتدا داده‌های هر کلاس به صورت تصادفی به ۱۰ قسمت برابر تقسیم می‌شود. سپس از هر کلاس ۹ قسمت برای آموزش و ارزیابی شبکه عصبی و یک قسمت برای آزمایش انتخاب می‌گردد. این فرایند ۱۰ بار تکرار شده و در نهایت صحت کلی به صورت میانگین ۱۰ آزمایش انجام شده در نظر گرفته شده است. بنابراین در آموزش شبکه عصبی از ۹۰ درصد تمام نمونه‌های استفاده شده است. از این تعداد ۷۰ درصد برای آموزش و ۲۰ درصد برای ارزیابی شبکه مورد استفاده قرار گرفته است.

با به‌کارگیری این روش صحت طبقه‌بندی برابر با ۹۸/۰۱٪ به‌دست آمد. جهت ارزیابی تأثیر هر ویژگی در دقت طبقه‌بندی‌کننده، از روش انتخاب ویژگی حذفی استفاده شد. درایه‌های جدول (۳) بیانگر صحت طبقه‌بندی حاصل از حذف ویژگی‌های متناظر با سطر و ستون همان درایه در ماتریس است.

۱۰ ویژگی اول در سطر و ستون ماتریس، ویژگی‌های استخراج شده از روش Timbre و ۴ ویژگی F1 الی F4، ویژگی‌های حاصل از فرآیند STFTLDA است.

$$Z_t = \frac{1}{2} \sum_{n=1}^N |sign(x[n]) - sign(x[n-1])| \quad (۱۲)$$

از نرخ عبور از صفر می‌توان جهت محاسبه میزان نویزی بودن سیگنال استفاده کرد. سیگنال نویزی دارای ZCR بالاتر است. شکل (۶) سیگنال در حوزه زمان و نمودار ZCR متناظر با آن را نشان می‌دهد.

مدت زمان هجوم سیگنال^۱ (LAT): مدت زمانی که طول می‌کشد سیگنال صوتی از آستانه قابل شنود بودن به حداکثر مقدار خود برسد را زمان هجوم سیگنال می‌نامند. این قسمت از سیگنال را قسمت گذرای سیگنال نیز می‌نامند و از رابطه زیر محاسبه می‌شود.

$$LAT = \log_{10}(T1 - T0) \quad (۱۳)$$

که مدت زمانی است که طول می‌کشد سیگنال به حداکثر دامنه خود برسد و $T0 < T1$ زمانی است که سیگنال در نقطه شروع هجوم است.

۴- نتایج

در ابتدا ۱۰ ویژگی استخراج شده طنین جهت طبقه‌بندی به طبقه‌بندی‌کننده شبکه عصبی اعمال شد. صحت طبقه‌بندی حاصل از این ۱۰ ویژگی به تنهایی ۷۸٫۷۵٪ به‌دست آمد که بیانگر توانایی نسبی این ویژگی‌ها در تفکیک سیگنال‌های صوتی ساطع شده از شناورهای مختلف است. در گام بعد اثر ترکیب این ۱۰ ویژگی با ۴ ویژگی STFTLDA بررسی شد.

همان‌طور که گفته شد، ویژگی‌هایی که توسط پردازش STFTLDA تولید شد توانست تفکیک‌پذیری شناورها را در طبقه‌بندی داده‌های سونار بهبود دهد. از طرفی روش پردازش STFT از یک نقص کلی در استخراج اطلاعات سیگنال‌های گذرا رنج می‌برد که ویژگی‌های طنین صوت به عنوان ویژگی‌های پیشنهادی جهت رفع این مشکل ارائه گردید. با توجه به این موارد، ایده استفاده ترکیبی از ویژگی‌های استخراج شده توسط فرآیندهای STFTLDA و ویژگی‌های طنین مطرح می‌شود.

برای این منظور همانند شکل (۱)، چهار ویژگی با استفاده از پردازش زمان-فرکانس STFTLDA و ۱۰ ویژگی با انجام عملیات محاسباتی بر پوش طیف فرکانسی و پوش زمانی سیگنال استخراج می‌شوند.

^۱ Log Attack Time

جدول (۳) ماتریس حاصل از روش انتخاب ویژگی حذفی.

ویژگی‌ها	SC	SF	SK	SS	ZCR	SFlat	Energy	PP	AP	LAT	F1	F2	F3	F4
SC	۹۷/۸۳	۹۷/۲۳	۹۷/۸۳	۹۷/۷۶	۹۷/۷۸	۹۷/۸۳	۹۷/۵۱	۹۷/۹۵	۹۷/۹۰	۹۷/۷۳	۹۵/۸۹	۹۵/۵۱	۹۶/۲۲	۹۶/۹۸
SF	۹۷/۲۳	۹۷/۶۹	۹۷/۸۶	۹۷/۴۹	۹۷/۶۹	۹۷/۶۹	۹۷/۸۳	۹۷/۷۶	۹۷/۸۳	۹۷/۶۹	۹۵/۷۲	۹۵/۳۹	۹۶/۱۸	۹۶/۸۵
SK	۹۷/۸۳	۹۷/۸۶	۹۷/۹۳	۹۸/۸۳	۹۸/۱۸	۹۷/۹۶	۹۷/۹۳	۹۷/۹۶	۹۳/۹۷	۹۷/۹۳	۹۶/۴۰	۹۶/۳۱	۹۷/۱۱	۹۷/۴۰
SS	۹۷/۷۶	۹۷/۴۹	۹۸/۸۳	۹۷/۵۹	۹۷/۶۴	۹۷/۵۹	۹۷/۸۶	۹۷/۷۱	۹۷/۷۴	۹۷/۵۹	۹۵/۷۷	۹۵/۳۳	۹۵/۹۹	۹۷/۰۱
ZCR	۹۷/۷۸	۹۷/۶۹	۹۷/۱۸	۹۷/۶۴	۹۷/۶۶	۹۷/۷۱	۹۷/۸۱	۹۷/۷۸	۹۷/۸۱	۹۷/۷۳	۹۵/۹۴	۶۵/۹۵	۹۶/۲۵	۹۶/۹۶
SFlat	۹۷/۸۳	۹۷/۶۹	۹۷/۹۶	۹۷/۵۹	۹۷/۷۱	۹۷/۶۴	۹۷/۸۶	۹۷/۶۹	۹۷/۸۳	۹۷/۷۶	۸۹/۹۵	۹۵/۶۰	۹۶/۱۸	۹۷/۱۰
Energy	۹۷/۵۱	۹۷/۸۳	۹۷/۹۳	۹۷/۸۶	۹۷/۸۱	۹۷/۸۶	۹۷/۸۱	۹۷/۹۸	۹۶/۷۶	۹۷/۷۳	۹۵/۷۲	۹۵/۴۵	۹۵/۸۷	۹۶/۷۴
PP	۹۷/۹۵	۹۷/۷۶	۹۷/۹۶	۹۷/۷۱	۹۷/۷۸	۹۷/۶۹	۹۷/۹۸	۹۷/۷۴	۹۷/۹۸	۹۷/۷۶	۹۶/۰۴	۹۵/۶۰	۹۶/۳۸	۹۶/۹۱
AP	۹۷/۹۰	۹۷/۸۳	۹۷/۹۳	۹۷/۷۴	۹۷/۸۱	۹۷/۹۳	۹۶/۷۶	۹۷/۹۸	۹۷/۷۸	۹۷/۶۹	۹۵/۶۵	۹۵/۵۳	۹۵/۸۹	۹۶/۷۶
LAT	۹۷/۷۳	۹۷/۶۹	۹۷/۹۳	۹۷/۵۹	۹۷/۷۳	۹۷/۷۶	۹۷/۷۳	۹۷/۷۶	۹۷/۶۹	۹۶/۷۶	۹۵/۹۴	۹۵/۴۸	۹۶/۱۸	۹۶/۹۶
F1	۹۵/۸۹	۹۵/۷۳	۹۶/۴۰	۹۵/۷۷	۹۵/۹۴	۹۵/۸۹	۹۵/۷۲	۹۶/۰۴	۹۵/۶۵	۹۵/۹۴	۹۵/۹۲	۸۷/۹۱	۹۳/۷۱	۹۴/۵۸
F2	۹۵/۵۱	۹۵/۳۹	۹۶/۳۱	۹۵/۳۳	۹۵/۶۵	۹۵/۶۰	۹۵/۴۵	۹۵/۶۰	۹۵/۵۳	۹۵/۴۸	۸۷/۹۱	۹۵/۶۲	۹۳/۰۵	۹۴/۰۵
F3	۹۶/۲۲	۹۶/۱۸	۹۷/۱۱	۹۵/۹۹	۹۶/۲۵	۹۶/۱۸	۹۵/۸۷	۹۶/۳۸	۹۵/۸۹	۹۶/۱۸	۹۳/۷۱	۹۳/۰۵	۹۶/۱۸	۹۴/۳۶
F4	۹۶/۹۸	۹۶/۸۵	۹۷/۴۰	۹۷/۰۱	۹۶/۹۶	۹۷/۱۰	۹۶/۷۴	۹۶/۹۱	۹۶/۷۶	۹۶/۹۶	۹۴/۵۸	۹۴/۰۵	۹۴/۳۶	۹۷/۰۶

جدول (۴) مقایسه عملکرد سیستم‌های طبقه‌بندی ارائه شده.

روش	تعداد ویژگی	صحت طبقه‌بندی (%)	توضیح
STFT	۴۰۰	۹۰,۳۸	بالاترین بازدهی در این روش
STFTLDA	۴	۹۲,۹۶	-
STFTLDA-TIMB (1)	۱۴	۹۸,۰۱	بدون انتخاب ویژگی
STFTLDA-TIMB (2)	۱۲	۹۸,۸۳	با انتخاب ویژگی

۴-۱- بررسی تاثیر طبقه‌بندی‌کننده بر عملکرد سیستم طبقه‌بندی

یکی از واحدهای اصلی در یک سیستم طبقه‌بندی سیگنال‌های سونار غیرفعال واحد طبقه‌بندی‌کننده است. فاکتورهای مختلفی را می‌توان برای بازدهی یک طبقه‌بندی‌کننده مثل صحت طبقه‌بندی و میزان زمان صرف شده برای ساختن مدل آن در نظر گرفت. یک طبقه‌بندی‌کننده نمی‌تواند روی تمام داده‌ها بازدهی مناسبی داشته باشد.

در جدول (۳) درایه‌های روی قطر اصلی نتایج حاصل از حذف هر ویژگی و درایه‌های غیر قطر اصلی نتایج حاصل از حذف همزمان ویژگی‌های متناظر با سطر و ستون آن درایه است. بیشترین کاهش در صحت طبقه‌بندی به ازای حذف ویژگی‌های به‌دست آمده از فرآیند STFTLDA می‌باشد.

از مجموع ۱۰۶ آزمایش انجام شده، حذف دو درایه منجر به بازدهی بالاتری نسبت به بازدهی حاصل از شرکت دادن کلیه ویژگی‌ها می‌شود. (درایه‌های پررنگ شده در جدول (۳)). بنابراین حذف همزمان ویژگی‌های انحراف طیف (SK) و وسعت طیف (SS)، بالاترین صحت طبقه‌بندی را ایجاد کرده است. جدول (۴) مقایسه‌ای از روش‌های ارائه شده و جدول (۵) ماتریس هم‌رخدادی^۱ متناظر با هر روش را نشان می‌دهد. ماتریس هم‌رخدادی، ماتریسی است که به واسطه آن می‌توان معیارهای مختلف ارزیابی طبقه‌بندی‌کننده‌ها را محاسبه کرد.

^۱ Confusion Matrix

برای طبقه‌بندی، بازدهی سیستم را کاهش می‌دهد، اما استفاده از چنین سیستم‌هایی قابل اعتمادتر و پایدارتر است. در جدول (۷) زمان اجرای بخش‌های مختلف الگوریتم پیشنهادی نشان داده شده است. سه سطر اول مربوط به زمان اجرای مربوط به تمام نمونه‌ها است. زمان‌ها با استفاده از یک رایانه شخصی با مشخصات AMD Athlon II X2 و RAM: 4 GB و 250 / 3 GHz processor Series Specs استفاده از نرم افزار MATLAB محاسبه شده است. با توجه به زمان‌های اجرا، مشخص است که استفاده از ترکیب دو الگوریتم استخراج ویژگی و سه طبقه‌بندی کننده، زمان ساخت مدل طبقه‌بندی را به شدت افزایش داده است. اما زمان اجرای تست یک نمونه پس از ساخته شدن مدل نهایی مناسب بوده و بنابراین الگوریتم پیشنهادی برای کاربردهای بی‌درنگ مناسب است.

جدول (۶) ارزیابی عملکرد طبقه‌بندی‌کننده‌های مختلف جهت طبقه‌بندی سیگنال‌های سونار.

طبقه‌بندی کننده	صحت طبقه‌بندی (%)	مدت زمان ساخت مدل (S)
RBF	۹۸٫۸۳	۵٫۷۷
پرسپترون چندلایه (MLP)	۹۸٫۸۱	۱۴٫۴۱
بیز	۹۶٫۲۳	۰٫۱
نیوی بیز	۹۲٫۸۱	۰٫۰۱
بگینگ	۹۸٫۷۸	۶٫۵۴
بوستینگ	۹۸٫۲۸	۷٫۲۳
زیر فضای تصادفی	۹۸٫۵۹	۶٫۰۸
طبقه‌بندی کننده چندتایی	۹۹٫۱۸	۱۵٫۱۲

جدول (۷) زمان اجرای بخش‌های مختلف الگوریتم پیشنهادی

الگوریتم	زمان اجرا (ثانیه)
پیش پردازش (تا قبل از مرحله استخراج ویژگی)	۲۳۱/۲۴
استخراج ویژگی‌های STFT	۷/۶۳
استخراج ویژگی TIMBRE	۹/۹۵
ساخت مدل طبقه بندی کننده	مطابق جدول ۶

جدول (۵) ماتریس هم رخدادی متناظر با هر روش.

	STFT					STFTLDA				
	V1	V2	V3	V4	V5	V1	V2	V3	V4	V5
V1	۲۲۰۵	۵۰	۲۱۰	۳۱۹	۶	۲۴۱۶	۶۹	۵۸	۲۴۷	۰
V2	۶۹	۲۶۷۱	۵	۲۸	۸	۵۵	۲۶۷۱	۱۷	۳۸	۰
V3	۷۰	۷	۲۴۹۷	۹۹	۵۷	۴۹	۱۵	۲۶۳۰	۳۵	۱
V4	۰	۱۲	۵۸	۲۵۹۴	۲۴	۲۲۰	۲۶	۲۵	۲۴۰۷	۰
V5	۱۲۳	۰	۹	۳۶	۱۲۱۵	۴	۰	۰	۲	۱۳۷۷
CE	۹۰/۳۸٪					۹۲/۹۶٪				
	STFTLDA-Timb1					STFTLDA-Timb2				
	V1	V2	V3	V4	V5	V1	V2	V3	V4	V5
V1	۲۷۲۸	۸	۲	۵۲	۰	۲۷۵۶	۷	۱	۲۶	۰
V2	۶	۲۶۷۴	۱	۱۰۰	۰	۶	۲۷۲۵	۱	۴۹	۰
V3	۲	۲	۲۷۱۵	۸	۳	۲	۱	۲۷۱۸	۶	۳
V4	۱۴	۲۱	۱۳	۲۶۴۰	۰	۱۱	۱۹	۱۰	۲۶۴۸	۰
V5	۰	۰	۰	۳	۱۳۸۰	۰	۰	۰	۳	۱۳۸۰
CE	۹۸/۰۱٪					۹۸/۸۳٪				

از این رو چندین طبقه‌بندی‌کننده معروف و پرکاربرد در حوزه‌های مختلف طبقه‌بندی‌کننده‌ها مثل طبقه‌بندی کننده‌های آماری، طبقه‌بندی‌کننده‌های شبکه عصبی و طبقه‌بندی‌کننده‌های تجمعی انتخاب شدند و جهت بررسی عملکرد و بازدهی آنان برای طبقه‌بندی سیگنال‌های سونار غیرفعال، مورد ارزیابی قرار گرفتند. طبقه‌بندی‌کننده‌های بیز^۱ و نیوی بیز^۲ به عنوان طبقه‌بندی‌کننده‌های آماری، طبقه‌بندی‌کننده‌های RBF و MLP^۳ به عنوان طبقه‌بندی‌کننده‌های شبکه عصبی و طبقه‌بندی‌کننده‌های بگینگ^۴، بوستینگ^۵ و زیر فضای تصادفی^۶ به عنوان طبقه‌بندی‌کننده‌های تجمعی مورد استفاده قرار گرفتند. با توجه به اینکه استفاده از یک طبقه‌بندی‌کننده در سیستم طبقه‌بندی ممکن است پایداری قابل اعتمادی نداشته باشد، از رای اکثریت بهترین طبقه‌بندی‌کننده‌های حوزه‌های مختلف برای طبقه‌بندی نهایی استفاده شده است.

بر این اساس با استفاده از نتایج مربوط به جدول (۶) سه طبقه‌بندی کننده RBF، بیز و بگینگ به عنوان طبقه‌بندی کننده‌های نهایی انتخاب شدند. اگرچه سیستمی که از چند طبقه‌بندی‌کننده استفاده می‌کند از نظر زمان صرف شده

⁴ Bagging

⁵ Boosting

⁶ Random Subspace Method

¹ Bayes Classifier

² Naive Bayes

³ Multi Layer Perceptron

۶- مراجع

- [1] Li, Q., Wang, J., and Wei, W., "An Application of Expert System in Recognition of Radiated Noise of Underwater Target", Proceedings of the OCEANS, San Diego, CA, USA, pp.404-408, 1995.
- [2] Ward, M. K., and Stevenson, M., "Sonar Signal Detection and Classification using Artificial Neural Networks", Canadian Conference on Electrical and Computer Engineering. Conference Proceedings. Navigating to a New Era. Vol.2, No.0840-7789, pp.717-721, 2000.
- [3] Welch, P. "The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method based on Time Averaging over Short, Modified Periodograms," IEEE Trans. Audio Electroacoust., Vol.15, No.2, pp.70-73, 1967.
- [4] Kang C., Zhang X., Zhang A., and Lin H., "Underwater Acoustic Targets Classification Using Welch Spectrum Estimation and Neural Networks," Advances in Neural Networks - ISNN, vol. 3173, pp. 930-935, 2004.
- [5] Atallah L., and Probert Smith P. J., "Using Wavelet Analysis to Classify and Segment Sonar Signals Scattered from Underwater Sea Beds," International Journal of Remote Sensing, Vol.24, No.21, pp.4113-4128, 2003.
- [6] Seixas, J. M., Damazio, D. O., Diniz, P. S. R., and Soares-Fillho, W., "Wavelet Transform as a Preprocessing Method for Neural Classification of Passive Sonar Signals," ICECS 2001. 8th IEEE Int. Conf. Electron. Circuits Syst. (Cat. No.01EX483), Vol.1, 2001.
- [7] Daubechies I., "The Wavelet Transform, Time-Frequency Localization and Signal Analysis," IEEE Trans. Inf. Theory, Vol.36, No.5, pp.961-1005, 1990.
- [8] Soares-Filho, W., De Seixas, J., and Pereira Caloba, L., "Principal Component Analysis for Classifying Passive Sonar Signals," Proceedings of the IEEE International Symposium on Circuits and Systems, Sydney, Australia, 2001.
- [9] Yang, S., and Li, Z., "Classification of Ship-Radiated Signals via Chaotic Features. Electronics Letters", Vol.39, No.4, pp.395-397, 2003.
- [10] Bao, F., Li, C., Wang, X., Wang, Q., and Du, S., "Ship Classification using Nonlinear Features of Radiated Sound: An Approach based on Empirical Mode Decomposition," The Journal of the Acoustical Society of America, Vol.128, No.1, pp.206-214, 2010.
- [11] Farrokhrooz, M., and Karimi, M., "Ship Noise Classification using Probabilistic Neural Network and AR model coefficients", Eur. Ocean. Vol.2, pp.1107-1110, 2005.
- [12] Filho, W. S., de Seixas, J. M., and de Moura, N. N., "Preprocessing Passive Sonar Signals for

۰/۰۱۲۶	تست یک نمونه با طبقه بندی کننده پیشنهادی (پیش پردازش+استخراج ویژگی+تست)
--------	---

۵- نتیجه گیری

یکی از متداول ترین روش های پردازش زمان-فرکانس در حوزه سونار، استفاده از روش تبدیل فوریه زمان کوتاه (STFT) است. اما روش STFT فقط از مؤلفه های ایستادن سیگنال در طبقه بندی داده ها استفاده می کند. از طرف دیگر بسیاری از پتانسیل های تفکیک کنندگی سیگنال در حوزه زمان، به دلیل پردازش پنجره های زمانی سیگنال از بین می رود. ویژگی های خروجی در روش STFT، ۴۰۰ عدد می باشد که این تعداد ویژگی زیاد موجب افزایش حجم پردازش و همچنین احتمال ایجاد اشباع آموزشی در طبقه بندی کننده می گردد. از این جهت در این مقاله برای رفع معایب یاد شده از الگوریتم استخراج ویژگی LDA برای دستیابی به ویژگی های متمایز کننده بهتر و کاهش ابعاد ویژگی استفاده شد. نتایج نشان داد که این روش (STFTLDA) صحت طبقه بندی را $2/58\%$ افزایش داده و از طرفی حجم پردازش نیز به دلیل کاهش ابعاد ویژگی (از ۴۰۰ ویژگی به ۴ ویژگی) کاسته شده است. از معایب روش STFTLDA عدم به کارگیری مولفه های غیرایستادن سیگنال ناشی از ماهیت روش STFT و همچنین افزایش احتمال ایجاد ناپایداری در طبقه بندی کننده به دلیل تعداد ویژگی کم (۴ ویژگی) بود. در این مقاله برای رفع این موارد از ویژگی های طنین صوت که دارای قابلیت ارائه خصوصیات رفتاری سیگنال های گذراست استفاده گردیده است. افزودن ویژگی های طنین صوت به ویژگی های استخراج شده از روش LDA، موجب شد تا ابعاد ویژگی به میزان مناسب (۱۲ ویژگی) برسد و از مولفه های غیرایستادن سیگنال استفاده گردد. با استفاده از ویژگی های جدید، صحت طبقه بندی بیش از 8% نسبت به سیستم های مبتنی بر روش STFT افزایش یافت. در نهایت با استفاده از یک طبقه بندی کننده چند تایی علاوه بر بهبود صحت طبقه بندی، قابلیت اعتماد به سیستم نیز افزایش داده شد و صحت طبقه بندی نیز تا $99/18\%$ افزایش پیدا کرد. با توجه به نتایج حاصل از آزمایشهای مختلف، زمان اجرای الگوریتم نهایی مطلوب بوده و می توان از آن در کاربردهای بی درنگ استفاده کرد.

- Analysis", 2nd ed. Peninsula Publishing, 2002.
- [24] Duda, R. O., Hart, P. E., Stork, D. G., "Pattern Classification", Wiley. 2nd Edition, 2000.
- [25] Cleveland, T., "Acoustic Properties of Voice Timbre Types and Their Influence on Voice Classification", The Journal of the Acoustical Society of America. Vol.61, No.6, pp.1622-1629, 1997.
- Neural Classification", IET Radar, Sonar Navigation., Vol.5, No.6, pp.605-612, 2011.
- [13] Zeng, X., and Wang, S., "Bark-Wavelet Analysis and Hilbert-Huang Transform for Underwater Target Recognition", Defence Technology. Vol.9, No.2, pp.115-120, 2013.
- [14] Howell, B.P., and Wood, S., "Passive Sonar Recognition and Analysis using Hybrid Neural Networks," in Proceedings of the IEEE Celebrating the Past—Teaming Toward the Future, San Diego, Calif, USA, pp.1917-1924, 2003.
- [15] Chen, C., Lee, J., and Lin, M., "Classification of under-Water Signals using Neural Network", Tamkang Journal of Science and Engineering, Vol.3, No.1, pp.31-48, 2000.
- [16] Xiyang, H., Jinfang, C., and Guangjin, H., "Application of BP Neural Network and Higher Order Spectrum for Ship-radiated Noise Classification", Proceedings of the 2nd International Conference on Future Computer and Communication, Wuhan, China, pp.712-716, 2010.
- [17] Soares-Filho, W., De Seixas, J., and Pereira Caloba, L., "Averaging Spectra to Improve the Classification of the Noise Radiated by Ships using Neural Networks", Proceedings of the Sixth Brazilian Symposium Neural Networks, Rio de Janeiro, Brazil, pp.156-161, 2000.
- [18] Bagheri, V., Shadlou Jahromi, M., Keshavarz, A., and Rostami, H., "Time-Frequency Signal Processing Based on Fractional Fourier Transform in Passive Sonar Classification", International Journal of Electronics Communication and Computer Engineering. Vol.5, No.6, pp.1366-1370, 2014.
- [19] Mosavi, M.R., Ghamgosar, M., and Khishe, A., "Classification of Sonar Data Set using Neural Network Trained by Gray Wolf Optimization", Journal of Neural Network World., Vol.26, pp.393-415, 2016.
- [20] Mosavi, M. R., and Khishe, M. "Training a Feed-Forward Neural Network using Particle Swarm Optimizer with Autonomous Groups for Sonar Target Classification", Journal of Circuits, Systems, and Computers (JCSC). Vol.26, No.11, 2017.
- [21] Mosavi, M. R., Khishe, M., and Akbarisani, M., "Neural Network Trained by Biogeography-based Optimizer with Chaos for Sonar Data Set Classification", Wireless Personal Communications (WPC). pp.1-20, 2017.
- [22] Khishe, M., Mosavi, M. R., and Kaveh, M., "Improved Migration Models of Biogeography-based Optimization for Sonar Data Set Classification using Neural Network", Applied acoustic. Vol.118, pp.15-29, 2017.
- [23] Burdic, W., "Underwater Acoustic Systems