

The image displays a massive, intricate piece of calligraphy in black ink on a white background. The text is composed of several lines of fluid, expressive script, likely Naskh or a similar style. The central focus is the name 'الله' (Allah) at the top, rendered in a bold, multi-line format. Below it, the name 'محمد' (Muhammad) is written in a large, flowing script. The entire composition is characterized by its dynamic, sweeping lines and varying stroke thicknesses, creating a sense of movement and depth. The black ink is applied with varying degrees of saturation, some areas appearing as solid black while others have more delicate, transparent edges.



دانشکده : برق و رباتیک  
گروه : الکترونیک

## عنوان

### تشخیص نوع شناورها با استفاده از صوت انتشاری زیرآب

دانشجو :  
علیرضا واردان

استاد راهنما :  
دکتر حسین مروی

استاد مشاور :  
دکتر هادی امیری

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

شهریور ۱۳۸۹

## دانشگاه صنعتی شاهرود

### دانشکده : برق و رباتیک گروه : الکترونیک

پایان نامه کارشناسی ارشد آقای  
علیرضا واردان

تحت عنوان:

تشخیص نوع شناورها با استفاده از صوت انتشاری زیرآب

در تاریخ ..... توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد  
مورد ارزیابی و با درجه ..... مورد پذیرش قرار گرفت.

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	نام و نام خانوادگی :		نام و نام خانوادگی :
	نام و نام خانوادگی :		نام و نام خانوادگی :

امضاء	نماینده تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی :		نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :

## تقدیر و تشکر

سپاس فراوان خدای را که به من قدرت نوشن داد

برخود لازم می‌دانم تشکر صمیمانه داشته باشم از :

- استاد راهنمای محترم جناب آقای دکتر حسین مروی و استاد مشاور محترم آقای دکتر امیری که با ارائه راهنمایی‌های خود اینجانب را در انجام هرچه بهتر پروژه یاری نمودند.
- پژوهشکده مهندسی جهاد کشاورزی جهت یاری اینجانب در تهیه بانک داده
- اعضای محترم هیئت داوری
- از تمامی اعضای خانواده‌ام بویژه پدر، مادر و همسرم که مرا در انجام این پروژه یاری نمودند

## چکیده :

نویز انتشاری زیرآب شناورها در دریا حاوی اطلاعاتی در مورد ماشین آلات آنها می‌باشد . از این اطلاعات می‌توان برای شناسایی آنها استفاده نمود . با توجه به تغییرات محیط دریا ، مشخصات ویژه کانال‌های انتقال صوت در زیرآب و تداخل امواج در محیط دریا ، تشخیص شناورها از طریق صوت انتشاری زیرآب ، فرایندی دشوار است . یکی از موارد بسیار مهم در تشخیص شناورها از طریق صوت انتشاری آنها در زیرآب استخراج ویژگی‌های منحصر به فرد از صوت شناور در زیرآب می‌باشد که امروزه مورد توجه محققین قرار گرفته است .

هدف اصلی این پایان نامه ارائه روشی برای شناسایی شناورها از طریق صوت انتشاری زیرآب آنها می‌باشد . در این پایان نامه از جمع کردن متوالی طیف‌های حاصل از قسمت‌بندی سیگنال ورودی و تشکیل یک تصویر باینری برای استخراج ویژگی استفاده شده است . مشخصه‌های استخراجی به عنوان ورودی به یک شبکه عصبی داده شده‌اند و سپس نوع شناور تعیین می‌گردد . آزمایش‌های مختلفی بر روی بانک صوت شامل ۲۰ فایل صوت کشته سنگین ، ۱۰ فایل صوت قایق ، ۶۰ فایل صوت کشتی متوسط ، ۲۰ فایل صوت زیردریایی و ۱۲ فایل صوت دلفین انجام شده است . نرخ تشخیص صحیح در ۷ کلاس ۹۷.۱۸٪ با سیگنال به نویز ۱۰ دسیبل و در ۵ کلاس ۹۶.۲۶٪ با همین سیگنال به نویز بدست آمده است .

## فهرست مطالب

۱.....	فصل اول : مقدمه
۲.....	۱-۱ مقدمه.
۴.....	۱-۲ ساختار پایان نامه.
۵.....	فصل دوم : انواع صدای تولیدی توسط کشتی ها.
۶.....	۱-۱ مقدمه
۶.....	۱-۲ نویز تولیدی توسط کشتی ها.
۷.....	۱-۲-۱ نویز ماشینی
۹.....	۱-۲-۲ پروانه ها
۱۰.....	۱-۲-۳ نویز انتشاری هیدرودینامیک
۱۰.....	۱-۳ نویز دریافتی توسط هیدروفون
۱۱.....	۱-۳-۱ نویز محیط
۱۶.....	۱-۳-۲ انتشار صوت در آب
۱۶.....	فصل سوم: مروری برخی از کارهای گذشته (روش های موجود در دسته بندی اصوات شناورها) ... ۱۶
۱۷.....	۱-۳ مقدمه
۱۷.....	۲-۳ متواسط گیری طیفی
۱۷.....	۲-۳-۱ پردازش داده
۱۹.....	۲-۳-۲-۳ متواسط گیری داده

۲۰.....	۳-۲-۳- کلاسیفایر عصبی
۲۱.....	۳-۳- کاربرد شبکه عصبی احتمالی با چندین مقدار پراکندگی در کلاس بندی نویز کشتی
۲۱.....	۱-۳-۳- مقدمه
۲۱.....	۲-۳-۳- PNN معمولی
۲۳.....	۳-۳-۳- PNN دارای چندین مقدار پراکندگی و روش جدید برآورد مقدار پراکندگی
۲۳.....	۱-۳-۳-۳- PNN دارای چندین مقدار پراکندگی
۲۴.....	۲-۳-۳-۳- روش تخمین پارامترهای پراکندگی با داده‌های آموزشی
۲۵.....	۳-۳-۳-۳- ویژگیهای جداسازی نویز کشتی‌ها
۲۶.....	۳-۳-۴- بانک داده صوتی مورد استفاده
۲۶.....	۴-۳- تبدیل موجک برای کلاس‌بندی عصبی
۲۶.....	۱-۴-۳- مقدمه
۲۶.....	۲-۴-۳- پردازش داده
۲۹.....	۳-۴-۳- کلاس‌بندی عصبی
۳۱.....	۳-۵-۳- شناسایی کشتی از طریق روش‌های مبتنی بر فراکتال
۳۱.....	۱-۵-۳- مقدمه
۳۲.....	۲-۵-۳- کلاسیفایر
۳۳.....	۳-۵-۳- حرکت براونی فراکتل تحلیلی
۳۶.....	۴-۵-۳- آنالیز بعد فراکتال
۳۷.....	۵-۵-۳- آنالیز موجک
۳۸.....	۶-۵-۳- بانک داده استفاده شده
۴۰.....	۶-۳- الگوریتم ترکیبی چند کلاسیفایر

۴۰	۱-۶-۳ - مقدمه
۴۰	۲-۶-۳ - مدل ترکیبی و جزئیات الگوریتم
۴۰	۱-۲-۶-۳ - مدل ترکیبی از کلاسیفایرهای چندگانه
۴۲	۲-۲-۶-۳ - الگوریتم ترکیبی کلاسیفایرهای چندگانه
۴۴	۷-۳ - استخراج ویژگی مرکب طیف خطی جداسازی شده نویز کشتی توسط بسته موجک
۴۴	۱-۷-۳ - مقدمه
۴۵	۲-۷-۳ - تبدیل بسته موجک
۴۷	۳-۷-۳ - استخراج ویژگی مرکب طیف خطی دمدوله شده بر اساس بسته موجک
۴۸	۱-۳-۷-۳ - تجزیه سیگنال نویز کشتی توسط بسته موجک
۴۹	۲-۳-۷-۳ - طیف جداسازی شده چندین زیرفضا مبتنی بر بسته موجک
۵۱	۳-۳-۷-۳ - روش ارزیابی داده براساس انتروپی
۵۱	۴-۳-۷-۳ - معیار بررسی طیف دمدوله شده زیرفضا چندتایی با استفاده از اطلاعات آنتروپی
۵۳	۵-۳-۷-۳ - استخراج ویژگی مرکب طیف خطی دمدوله شده نویز کشتی
۵۵	۳-۸-۳ - کاربرد سیستم هوشمند در شناسایی نویز انتشاری از هدف زیر آب
۵۵	۱-۸-۳ - مقدمه
۵۵	۲-۸-۳ - آنالیز مشخصات نویز زیر آب
۵۶	۳-۸-۳ - الگوریتم تصمیم گیری
۶۰	۴ - الگوریتم پیشنهادی
۶۱	۱-۴ - الگوریتم پیشنهاد شده
۶۲	۱-۱-۴ - تغییر نرخ نمونه برداری

۶۲	۴-۱-۲- تابع خود همبستگی
۶۳	۴-۱-۳- تبدیل فوریه سریع
۶۴	۴-۱-۴- استخراج ویژگی
۶۴	۴-۱-۵- کласیفایر عصبی
۷۰	۴-۲- بانک داده مورد استفاده
۷۱	۵- نتایج و مقایسات
۷۲	۵-۱-۱- تغییر مشخصات
۷۲	۵-۱-۱-۱- تغییر همسایگی
۷۴	۵-۱-۱-۲- تغییر سیگنال به نویز
۷۷	۵-۱-۳- تغییر تعداد ویژگی‌های فرکانسی
۷۹	۵-۱-۴- تغییر تعداد فرکانس‌های انتخابی
۸۱	۵-۲- مقایسه الگوریتم پیشنهادی با چندالگوریتم موجود
۸۱	۵-۲-۱- سیگنال به نویز ۵- دسیبل
۸۲	۵-۲-۲- سیگنال به نویز صفر دسیبل
۸۳	۵-۲-۳- سیگنال به نویز ۵ دسیبل
۸۵	۵-۲-۴- سیگنال به نویز ۱۰ دسیبل
۸۶	۵-۲-۵- مقایسه میزان شناسایی کلی کلاس‌ها در سیگنال به نویزهای متفاوت با روش‌های مذکور
۸۷	۵-۳- مقایسه عملکرد سیستم‌ها با تغییر تعداد کلاس‌ها
۸۹	۵-۴- پیشنهاد ادامه کار
۹۰	۶- مراجع

# فهرست اشکال

..... ۷	شکل ۱-۲ محدوده فرکانسی منابع نویز کشتی
..... ۸	شکل ۲-۲ منابع نویز ماشینی کشتی
..... ۱۰	شکل ۲-۳ اثر سرعت بر طیف توان نویز کشتی
..... ۱۳	شکل ۲-۴ سطح طیف نویز کشتی
..... ۱۳	شکل ۲-۵ طیف نویز محیط تحت وضعیت‌های متفاوت
..... ۱۵	شکل ۲-۶ سرعت صوت در آب مقطر و آب دریا
..... ۱۸	شکل ۳-۱ بلوک دیاگرام روش متوسط‌گیری طیفی
..... ۱۸	شکل ۳-۲ اسپکتوگرام کشتی
..... ۱۹	شکل ۳-۳ طیف متوسط
..... ۲۰	شکل ۳-۴ ساختار شبکه عصبی
..... ۲۳	شکل ۳-۵ نمودار پراکندگی
..... ۲۷	شکل ۳-۶ اسپکتوگرام طیف کشتی
..... ۲۸	شکل ۳-۷ بانک فیلتر
..... ۲۹	شکل ۳-۸ نمودار پردازش
..... ۳۵	شکل ۳-۹ نمونه صوتی $\sigma$
..... ۳۵	شکل ۳-۱۰ نمونه صوتی $H$
..... ۳۷	شکل ۳-۱۱ نمونه صوتی $D$
..... ۳۷	شکل ۳-۱۲ نمونه‌های $fBm$ $D$
..... ۳۹	شکل ۳-۱۳ طیف توان کشتی‌ها

۳۹	شکل ۱۴-۳ طیف توان fBm
۴۱	شکل ۱۵-۳ مدل ترکیبی چند کلاس بند
۴۴	شکل ۱۶-۳ استخراج ویژگی مرکب طیف خطی
۴۵	شکل ۱۷-۳ طیف مدوله شده
۴۷	شکل ۱۸-۳ یک درخت باینری
۵۰	شکل ۱۹-۳ فلوچارت طیف مدوله شده
۵۰	شکل ۲۰-۳ طیف مدوله شده
۵۴	شکل ۲۱-۳ استخراج ویژگی مرکب
۵۴	شکل ۲۲-۳ طیف مدوله شده
۵۹	شکل ۲۳-۳ روش آنالیز خوشهای
۵۹	شکل ۲۴-۳ بلوک دیاگرام سیستم خبره
۶۱	شکل ۲۵-۳ بلوک دیاگرام الگوریتم پیشنهادی
۶۲	شکل ۲۶-۳ طیف فرکانسی یک شناور نمونه
۶۴	شکل ۲۷-۳ پنجره همینگ
۶۴	شکل ۲۸-۴ اسپکتوگرام نمونه
۶۶	شکل ۲۹-۴ ماتریس H
۶۷	شکل ۳۰-۴ انتخاب بین
۷۱	شکل ۳۱-۴ تابع فعال‌ساز خطی
۷۱	شکل ۳۲-۴ تابع فعال‌ساز نمایی
۷۱	شکل ۳۳-۴ تابع فعال‌ساز لگاریتمی

شکل ۴-۱ شبکه عصبی پیشرو	۷۲
شکل ۵-۱ نمونه‌های سیگنالی	۷۷
شکل ۵-۲ نمونه‌های ماتریس $H$	۷۸
شکل ۵-۳ نمونه‌های ماتریس $H$ با تغییر طول قسمت‌بندی	۸۱
شکل ۵-۴ نمودار شناسایی با تغییر طول قسمت‌بندی	۸۲
شکل ۵-۵ ماتریس $H$ حاصل از کاربرد مقدار میانه	۸۵
شکل ۵-۶ نمودار نرخ تشخیص با استفاده از مقدار استانه	۸۶
شکل ۵-۷ نمودار نرخ شناسایی در شرایط نویزی مختلف	۸۸
شکل ۵-۸ ماتریس $H$ با شرایط نویزی متفاوت	۸۹

# جداول

جدول ۱-۵ بانک داده مورد استفاده	۷۶
جدول ۲-۵ میزان شناسایی کلاس‌ها با تغییر طول قسمت‌بندی	۸۰
جدول ۳-۵ میزان شناسایی کلاس‌ها با تغییر مقدار استانه	۸۴
جدول ۴-۵ مقایسه کارایی	۸۷

# فصل اول

مقدمه

## ۱.۱ مقدمه

امروزه مسئله کلاس‌بندی شناورها از طریق سیگنال‌های انتشاری صوتی تبدیل به موضوع جذابی شده است. این سیگنال‌ها متشکل از سیگنال‌های سونار<sup>۱</sup> پسیو انتشار یافته از شناورهای مختلف بعلاوه سیگنال‌های گذرای زیرآب چون صدای وال‌ها، صدای خوک دریایی، صدای شکستن کوه یخ و غیره می‌باشد. هر نوع سیگنال با توجه به اینکه هر شناور یک ترکیب منحصر به فرد از موتورها، پروانه‌ها، شکل بدن، صوت ایجاد شده توسط فعالیت کارکنان و ... است، بنابراین نویز تولیدی منحصر به فرد بوده و مشخصات متمایز مخصوص به خود را دارد و متخصص یا با شنیدن یا با نگریستن به اسپکتوگرام<sup>۲</sup> سیگنال سونار، نوع سیگنال را تعیین می‌کند.

کار بر روی مدل نمودن سیگنال‌های زیرآب انتشاری از شناورها منجر به این نتیجه می‌شود که منابع سیگنال شناورها را می‌توان به سه قسمت اصلی، سیگنال‌های ناشی از ماشین آلات<sup>۳</sup>، سیگنال‌های ناشی از پروانه<sup>۴</sup> و سیگنال‌های هیدرودینامیک<sup>۵</sup> تقسیم کرد. سیگنال‌های ماشین آلات از طریق قسمت‌های گوناگون حرکتی شناور همچون پمپ‌ها، لوله‌ها، آرمیچر موتور و غیره ایجاد می‌شود. سیگنال‌های پروانه، مؤلفه‌های توinal<sup>۶</sup> طیف پیوسته ناشی از سیگنال‌های کویتاسیون<sup>۷</sup> را تولید می‌کند. سیگنال‌های هیدرودینامیک متشکل از سیگنال‌های گوسی تولید شده از طریق برخورد بدن<sup>۸</sup> کشتی و جریان آب در زیر بدن می‌باشد که این سیگنال‌ها شبیه به سیگنال‌های محیطی در دریا می‌باشد.

---

<sup>۱</sup>Sonar

<sup>۲</sup>Spectrogram

<sup>۳</sup>Machinery

<sup>۴</sup>Propeller

<sup>۵</sup>Hydrodynamic

<sup>۶</sup>Tonal components

<sup>۷</sup>Cavitation

<sup>۸</sup>Hull

بنابراین طیف سیگنال‌های انتشاری متشکل از دو نوع طیف می‌باشد . اولی طیف باندباریک<sup>۹</sup> با طیف ناپیوسته متشکل از مؤلفه‌های خطی<sup>۱۰</sup> در فرکانس‌های گسسته می‌باشد . دیگری طیف باندپهن<sup>۱۱</sup> با طیفی پیوسته است . سیگنال‌های انتشاری از شناور ترکیبی از این دو نوع سیگنال‌ها هستند .

متأسفانه مشخصه صوتی<sup>۱۲</sup> در مسیر انتشار با توجه به نویز محیط موجود در دریا و تداخل<sup>۱۳</sup> امواج تغییر می‌یابد . در نتیجه فرایند تشخیص شناور را از طریق صوت انتشاری آن دشوار می‌سازد . این پایان‌نامه قصد دارد با پردازش طیف باند باریک حاصل از تبدیل فوریه روشی برای تشخیص نوع شناور از طریق صوت انتشاری زیرآب آن ارائه نماید . تبدیل فوریه برای آنالیز سیگنال‌های صوتی در مقالات مختلف استفاده شده است . این تبدیل اگرچه مفید و دارای پیاده‌سازی ساده‌ای است ولی برای آنالیز رفتار سیگنال‌های صوتی گذرای زمان کوتاه مناسب نمی‌باشد . برای رفع این مشکل از تبدیل فوریه زمان کوتاه<sup>۱۴</sup> استفاده می‌شود .

### ۲.۱. ساختار پایان‌نامه

در فصل دوم این پایان‌نامه به بررسی منابع تولیدی اصوات انتشاری شناورها ، طیف ایجاد شده توسط هر یک از این منابع و عوامل مؤثر بر اصوات تولیدی منابع همچون نویز محیط و درجه شوری آب دریا از لحظه تولید صوت تا لحظه دریافت در هیدروفون می‌پردازیم .

در فصل سوم برخی روش‌های ارائه شده تاکنون مانند شبکه عصبی احتمالاتی با چندین مقدار پراکندگی [۹] ، الگوریتم ترکیبی شامل چندین کلاس‌بند [۲۴] در زمینه شناسایی و تشخیص نویز زیرآب شناورها مختصراً معرفی می‌شوند .

<sup>۹</sup> Narrow-Band

<sup>۱۰</sup> Line components

<sup>۱۱</sup> Broad-Band

<sup>۱۲</sup> Acoustic Signature

<sup>۱۳</sup> Short-time Fourier Transform

<sup>۱۴</sup> Interference

در فصل چهارم پایان نامه مراحل الگوریتم پیشنهاد شده بیان شده است . در این روش پیشنهادی با پردازش طیف باند باریک شناور و جمع کردن متوالی طیف های حاصل از قسمت بندی سیگنال ورودی یک تصویر باینری عنوان یک ماتریس ویژگی ایجاد می گردد . از این ماتریس بخش هایی عنوان بردار ویژگی استخراج و این بردار عنوان ورودی شبکه عصبی جهت تشخیص نویز انتشاری انواع شناورها بکار می رود .

در فصل پنجم ابتدا بانک داده مورد استفاده شامل ۲۰ فایل صوت کشتی سنگین ، ۱۰ فایل صوت قایق ، ۶۰ فایل صوت کشتی متوسط ، ۲۰ فایل صوت زیردریایی و ۱۲ فایل صوت دلفین ، معرفی می گردد . سپس از الگوریتم پیشنهادی شبیه سازی شده و آنگاه به ارزیابی نتایج آن در بانک داده می پردازیم . در آخر نتایج حاصل از الگوریتم پیشنهادی با دو روش موجود را با استفاده از بانک داده مقایسه می نماییم .

# فصل دوم

بررسی اصوات انتشاری  
شناورها در آب و عوامل  
مؤثر بر آنها

## ۱-۲- مقدمه

از انجاییکه هدف اصلی این پایان نامه ارائه الگوریتمی جهت تشخیص شناورها توسط سیستم اتوماتیک با استفاده از آنالیز داده های صوتی تولیدی آنهاست . برای درک و حل این مسأله لازم است بدانیم نویز شناورها چگونه و چرا تولید می شود؟ چطور در دریا منتشر میشود؟ چطور بادیگر نویز ها تریکیب میگردد؟ و چگونه توسط هیدروفون دریافت میشود؟ این نکته را هم قابل ذکر است که در برخی از تحقیقات صوت زیر اب شناورها را نویز شناور نیز نامیده اند .

## ۲-۱- نویز تولیدی توسط شناورها

سه منبع اصلی تولید نویز کشتی ها عبارتند از:

(الف)- نویز ماشینی<sup>۱</sup> (نیرو محرکه کشتی و ماشین الات کمکی)

(ب)- پروانه ها

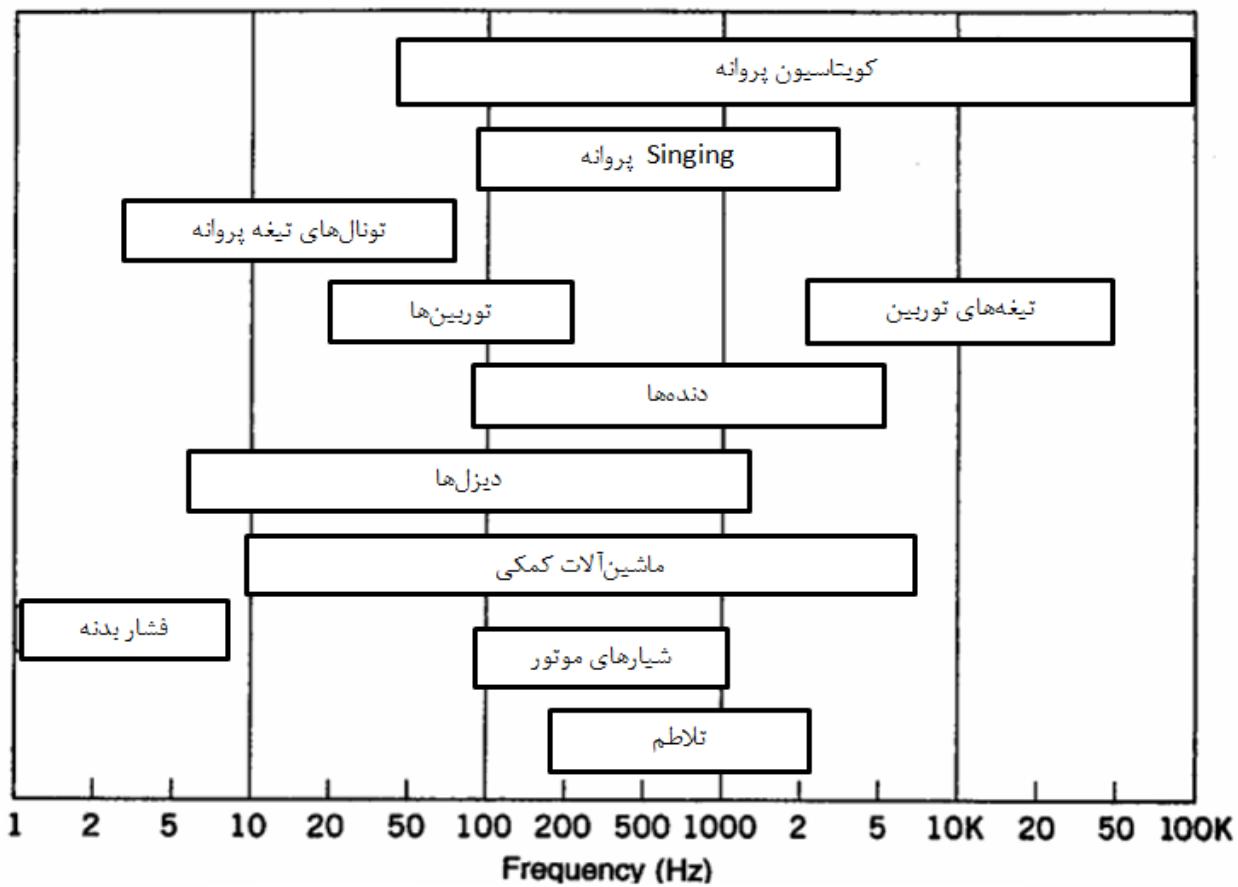
(پ)- نویز هیدرو دینامیک<sup>۲</sup> ناشی از جریان نامنظم اب گذرندهع از زیر کشتی

هر کدام از این منابع باند فرکانسی مخصوصی دارند و تحت شرایط متفاوت رفتار متفاوتی از خود نشان می دهند . بیشتر اطلاعات در محدوده فرکانسی ۱۰ هرتز تا ۲ کیلوهرتز میباشد . شکل ۱-۲ این محدوده فرکانسی نویز تولیدی کشتی ها را نشان میدهد .

## ۲-۲- نویز ماشینی

در شرایط عادی نویز ماشینی منبع نویز غالب بر دیگر منابع در کشتی ها می باشد . ماشین الات مختلف ، نویز های متفاوتی تولید می کنند . شکل ۲-۲ منابع تولید نویز ماشینی را نشان می دهد.

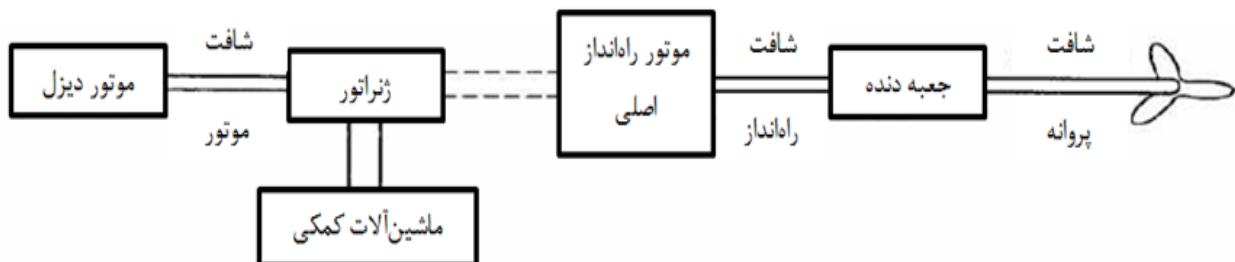
<sup>۱</sup>machinery noise



[۲] شکل ۱-۲- محدوده فرکانسی منابع نویز کشتی [۲]

موتورهای دیزلی دارای تعدادی سیلندر هستند که میزان سرعت احتراق در این سیلندرها فرکانس غالب نویز تولیدی معین می‌کند . موتورهای توربین نسبت به دیزل ها نویزی‌تر می باشند اما میتوان نویز آنها را در صورت نیاز به شدت کاهش داد . فرکانس تولیدی آنها ناشی از نامتعادل بودن تیغه ها است . موتور های الکتریکی و ژنراتورها که شافت اصلی آنها تولید نویز می نماید . از دیگر منابع اصلی نویز جعبه دنده است که ارتباط میان ماشین الات محرک و شافت محرک را برقرار می کند . تحت شرایطی حتی نویز تولیدی آنها از موتورهای دیزل نیز بیشتر می گردد . نویز ماشینی کشتی از طریق بدن کشتی به آب دریا منتقل می شود . این انتقال اثر

شدیدی روی صوت دارد . بیشترین نویز ماشینی در فرکانس‌های اصلی و هارمونیک‌های آنها متمرکز شده‌اند . این فرکانس‌ها را تونال نویز<sup>۳</sup> یا نویز باند باریک<sup>۴</sup> می‌نامند بدلیل انکه به صورت پیک‌های باریکی در طیف فرکانسی شناور بنظر می‌آیند . تحت شرایط متفاوت ماشین‌آلات شناور ، رفتارهای متفاوتی فرکانسی دارند . فرکانس نویز ماشین‌آلات مرتبط با نیرو محركه اصلی با افزایش سرعت ، افزایش می‌یابد ، در حالیکه فرکانس نویز ماشین‌آلات کمکی چون ژنراتورها در این شرایط تغییر نمی‌کند . شکل ۲-۳- تأثیر سرعت را بر طیف توان شناور نشان می‌دهد . فرکانس‌ها میتوانند اطلاعات مهمی در مورد نوع ماشین و وضعیت استهلاک آنها بدهد . ماشین‌آلات مقداری نویز باند وسیع<sup>۵</sup> هم تولید می‌کنند . بر خورد پیستون‌ها به کناره‌های سیلندرها تولید نویز می‌کند و همراه با حرکت شافت‌ها در بیشتر قسمت‌های موتور ایجاد لرزش می‌کنند .

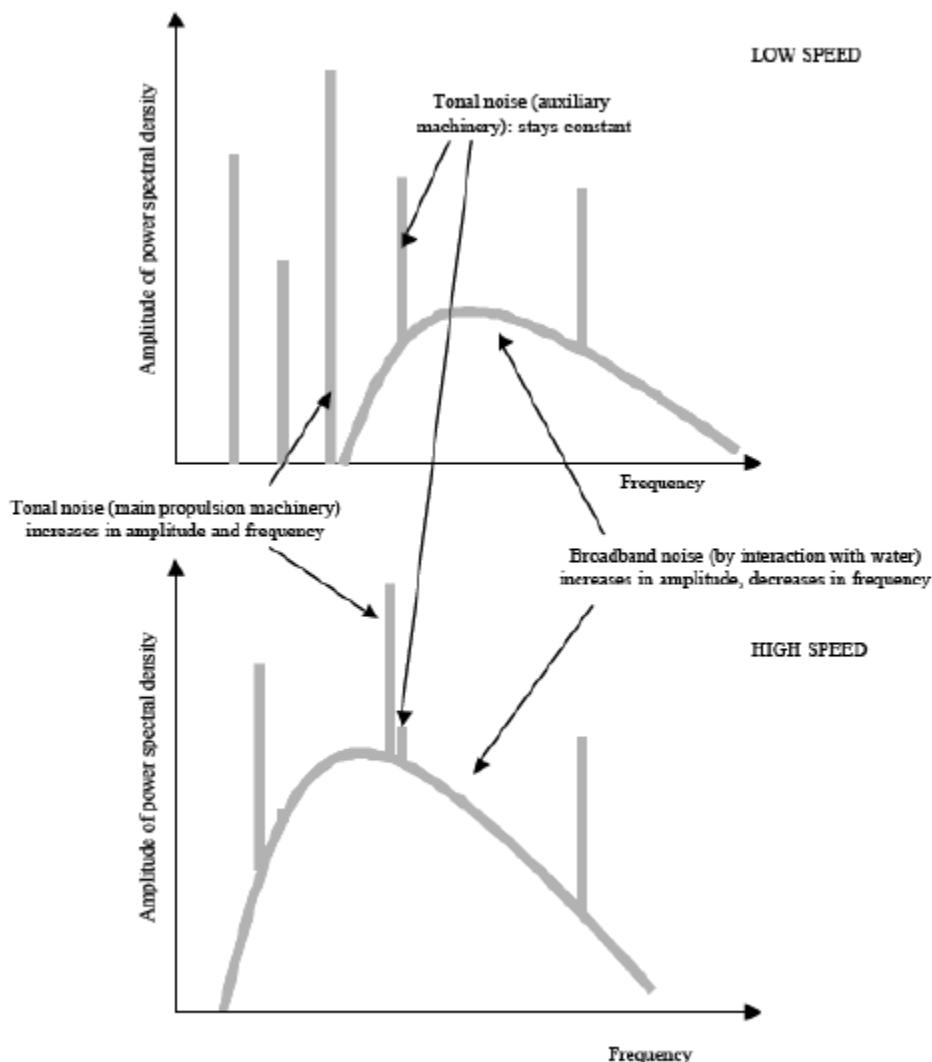


شکل ۲-۲- منابع نویز ماشینی کشتی [۲]

<sup>۳</sup>Tonal noise

<sup>۴</sup>narrow band noise

<sup>۵</sup>broad band noise



[۲] ۳-۲- اثر سرعت بر طیف توان نویز کشتی

## ۲-۲-۲- پروانه ها

نویز پروانه خارج از بدنه کشتی توسط عمل چرخش پروانه و حرکت شناور در آب و به دلیل تولید حباب ایجاد می شود . زمانیکه پروانه میچرخد ، فشار منفی در لبه و وجود پره های کشتی بوجود می آید . اگر این فشارمنفی به اندازه کافی بزرگ باشد ، آب می شکافد و حفره هایی به صورت حباب ظاهر می شوند به این

پدیده کویتاسیون<sup>۶</sup> می گویند . یک پالس صوتی کوتاه مدت به سبب ترکیدن این حباب ایجاد میشود . این پالس های صوتی در مجموع باعث ایجاد یک نویز فرکانس بالادر طیف نویز شناور می شوند . به دلیل زیاد بودن تعداد حباب های ایجاد شده می توان طیف آنها را پیوسته فرض کرد . در فرکانس های بالا ، این طیف دارای شبیه ۶- دسیبل بر اوکتاو است و در فرکانس های پایین ، طیف نویز مربوطه با افزایش فرکانس ، افزایش می یابد . بنابراین یک حداکثر در این طیف وجود دارد که برای کشتی ها و زیر دریایی ها بین ۱۰۰ هرتز تا ۱۰۰۰ هرتز اتفاق می افتد . مکان این حداکثر با افزایش سرعت و کاهش عمق به فرکانس های پایین تر تغییر پیدا می کند (شکل ۳-۲) .

زیر دریایی های مدرن برای کاهش نویز ناشی از ترکیدن حباب ها از پروانه های بزرگ با تعداد تیغه بسیار استفاده می نمایند. اگر چه با افزایش سرعت هر نوع پروانه ای شروع به ایجاد کویتاسیون می نماید . پروانه هایی با ساخت نامرغوب یا معیوب در برخی سرعت های خاص ایجاد یک صوت بلند و نویز متمایزی به نام singing می کنند .

### ۲-۲-۳- نویز انتشاری هیدرو دینامیک

این نویز بر اثر بالا و پایین رفتن سطح دریا و نیز جریان نامنظم آب و بالا و پایین رفتن آن و برخورد آن با بدنه ممکن است مستقیماً در فواصل دور ایجاد صدا کند و یا مهمتر از آن اینکه احتمال دارد قسمت هایی از بدنه شناور را به ارتعاش در بیاورد .

---

<sup>۶</sup>Cavitation

## ۲-۳- نویز دریافتی توسط هیدروفون<sup>۷</sup>

نویز انتقال یافته کشته که دریا تا زمانی که توسط هیدروفون دریافت می‌شود، با دیگر اصوات منابع موجود در دریا ترکیب می‌گردد. حال اثر هریک از این اصوات منابع را بررسی می‌کنیم.

### ۲-۱- نویز محیط

نویز محیط عبارت است از نویزی که در محیط انتشارناهمگن دریا توسط یک هیدروفون همه جهتی دریافت می‌شود. آزمایشات گوناگون انجام شده نشان دادند عوامل ایجاد کننده نویز های انتشاری در محیط دریا دارای طیف فرکانسی از یک هرتز تا ۱۰۰ کیلو هرتز می‌باشند که تقریباً تمام فرکانس‌های موجود را تحت پوشش قرار می‌دهند [۱]. عوامل ایجاد کننده نویز محیط عبارتند از:

#### (الف)- مداخله انسان :

بدلیل انتشار آسان و سریع صوت در آب، صدای ناشی از کشتیرانی در فواصل بسیار دور نیز شنیده می‌شود. با وجود اینکه شاید کشته‌ها به صورت مجرزا قابل تشخیص نباشند اما نویز آنها با هم ترکیب شده و یک صدای هم‌همه با پهنه‌ای باند پهن ایجاد می‌کند. این صدا تا فواصل طولانی انتشار می‌یابند، طیف آنها توسط تابع تبدیل دریا تغییر می‌یابد. به طور نمونه فرکانس‌های بالا فیلتر شده و اثر ان یک نویز هم‌همه با فرکانس پایین است.

#### (ب)- جریانهای ناشی از جذر و مد و اثرات هیدرو استاتیکی امواج :

جذر و مد دریا سبب تغییرات فشار هیدرواستاتیکی با دامنه نوسانات زیاد در طیف فرکانسی پایین می‌گردد. امواج سطحی نیز یک منبع تغییرات فشار هیدرواستاتیکی در عمق دریا هستند.

<sup>۷</sup>hydrophone

(پ)-**تلاطم سطحی:**

تلاطم سطحی اساساً به خاطر عمل متقابل بین باد و آب اقیانوس ایجاد میگردد . باد با سرعت بیشتر موجب ایجاد صوتی با دامنه بیشتر توسط موج ها و حباب ها می شود . باند فرکانسی این نویز بین ۵۰۰ هرتز تا ۲۵ کیلوهرتز است . در حالت کلی این نویزبه حالت باد و نیروهای دریا وابسته است .

(ت)-**منابع زیستی :**

حیوانات و گیاهان دریایی نیز تولید صدای قابل ملاحظه‌ای می کنند . بسیاری از پستانداران دریایی همچون وال‌ها برای مسیریابی از صوت استفاده می کنند . یکی از بیشترین منابع صوت این گروه توسط میگوها تولید میشود .

(ث)-**اغتشاشات ناشی از زمین لرزه در کف دریا موجب ایجاد نویز در دریا در فرکانس‌های پایین میشود .** این نویز خیلی قوی و ممتد است . به طور کلی نویز های حاصل در محدوده فرکانسی پایین بین یک تا ۱۰ هرتز قرار دارند .

(ج)-**شکستن کوه های یخ :**

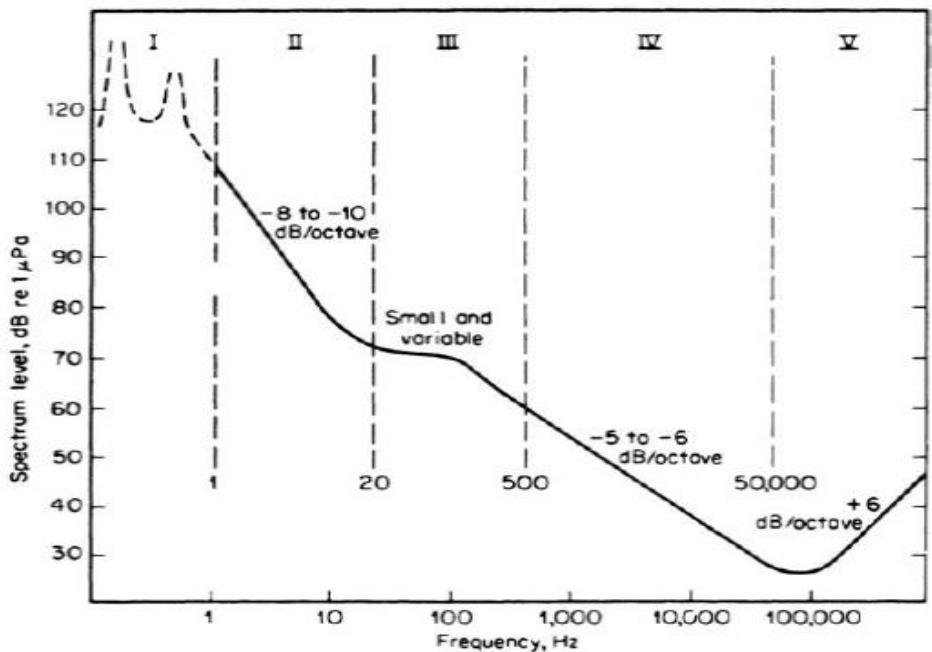
تغییر دما در یخ های قطبی سبب ایجاد ترک و نهایتاً شکسته شدن کوه های عظیم یخی می شود و صدای ناشی از آن بسیار بلند و گوش خراش است .

(چ)-**باران و برف :**

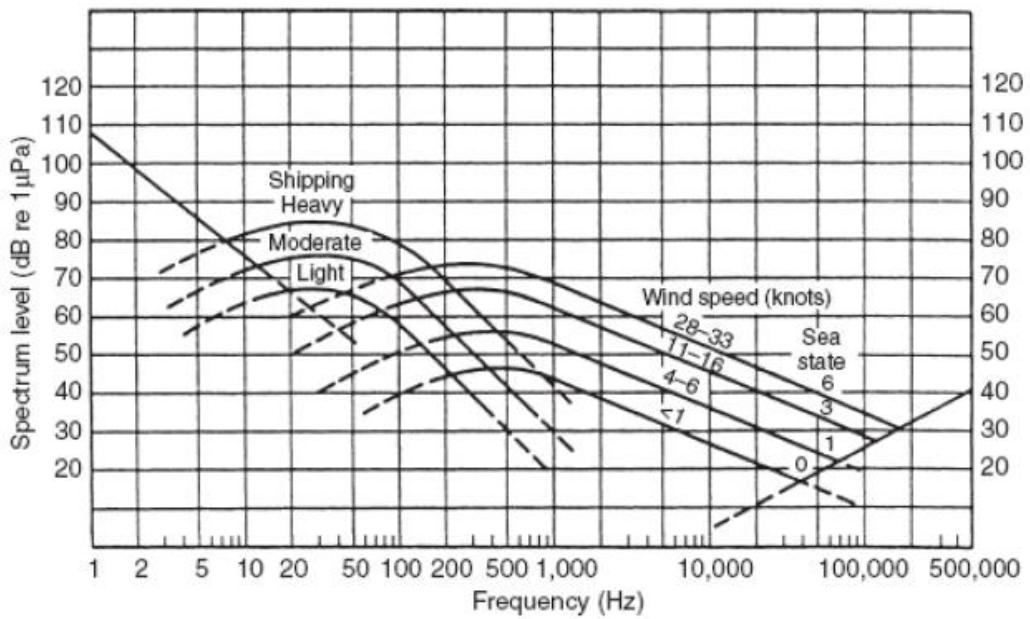
باران و برف به همراه کولاک نویز قابل ملاحظه ای را ایجاد میکنند.

(ح)-**نویز حرارتی :**

در فرکانس‌های بالا محدودیتی را در حساسیت هیدروفون ایجاد می کند.



شکل ۲-۴- سطح طیف نویز در دریا [۱]



شکل ۲-۵- طیف نویز محیط تحت وضعیت‌های مختلف

شکل ۴-۲ طیف انواع نویز های محیط را که بررسی شد ، نمایش میدهد . طیف مذکور از چند قطعه با شبیه های متفاوت و رفتار گوناگون در شرایط مختلف تشکیل شده است . این پیچیدگی طیف به دلیل گوناگونی منابع نویز در محدوده فرکانسی مختلف قرار دارد .

در شکل ۵-۲ طیف نویز تحت وضعیت های مختلف دریا نشان داده شده است. طیف نویز محسسط در هر منطقه و در هر زمانی بالانتخاب منحنی وضعیت کشتیرانی و سرعت باد مناسب تقریب زده می شود.

### ۲-۳-۲- انتشار صوت در آب

یکی از مهمترین پارامترهایی که رفتار صوت را در آب تعیین می کند ، سرعت آن در آب است . سه عامل زیر سرعت صوت در آب را کنترل می کنند:

۱- حرارت

۲- فشار که در اثر عمق زیاد به وجود می اید

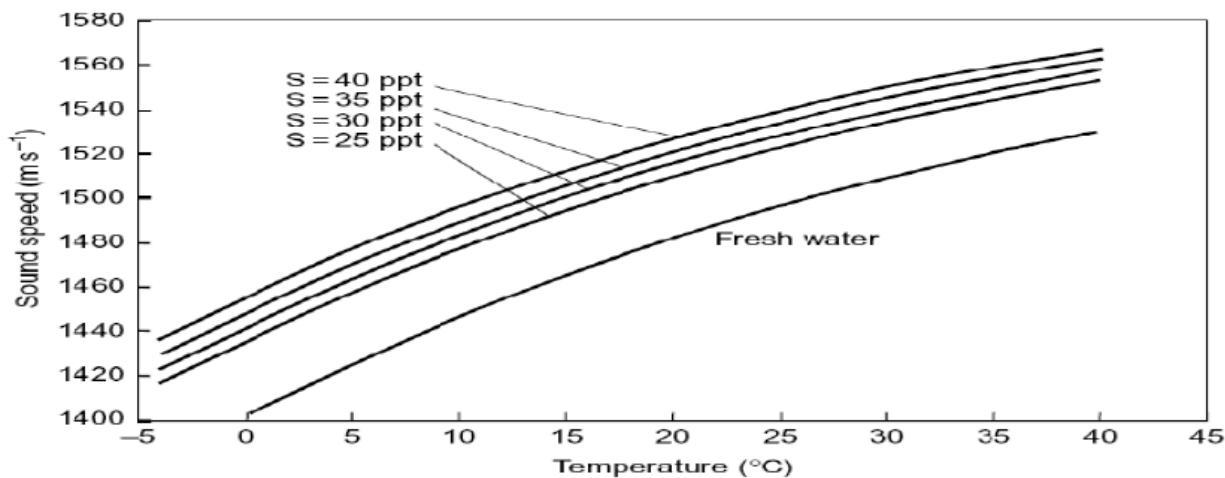
۳- سوری یا غلظت

حرارت مهمترین عامل اثر گذار بر روی سرعت صوت در آب است . با تغییرات درجه حرارت سرعت صوت نیز تغییر می کند و به ازاء اضافه شدن هر درجه حرارت ، سرعت صوت  $1.22$  متر بر ثانیه تا  $2.44$  متر بر ثانیه اضافه می شود .

اگر آب تحت فشار باش سرعت صوت در آن بیشتر خواهد شد . سرعت صوت برای هر  $100$  فوت عمق  $61.0$  متر بر ثانیه اضافه می شود .

در ازاء هر یک در هزار افزایش غلظت اب سرعت صوت در آن به مقدار  $1.22$  متر بر ثانیه اضافه می شود .

سرعت صوت در آب تقریباً ۱۴.۵ m/s برابر سرعت صوت در هوا می باشد. شکل ۲-۶ سرعت صوت را بر حسب درجه حرارت و غلظت مختلف نشان میدهد.



شکل ۲-۶- سرعت صوت در آب مقطر و آب دریا در عمق صفر برای درجه شوری و حرارت‌های مختلف

# فصل سوم

مرور کارهای گذشته

---

---

## فصل سوم:

---

---

### مروور کارهای گذشته

### ۱-۳- مقدمه

مطالعات در زمینه تعیین منابع نویز زیرآب دارای سابقه‌ای طولانی است . بعداز جنگ جهانی دوم و با شروع جنگ سرد تحقیقات در این زمینه به شدت افزایش یافت . این تحقیقات بسیار مهم و طبقه بندي شده‌اند . البته برخی مقالات هم که جزء تحقیقات طبقه‌بندي شده نمی‌باشند به این موضوع پرداخته‌اند . در این فصل به مرور برخی از این مقالات و بانک داده مورد استفاده آنها می‌پردازیم .

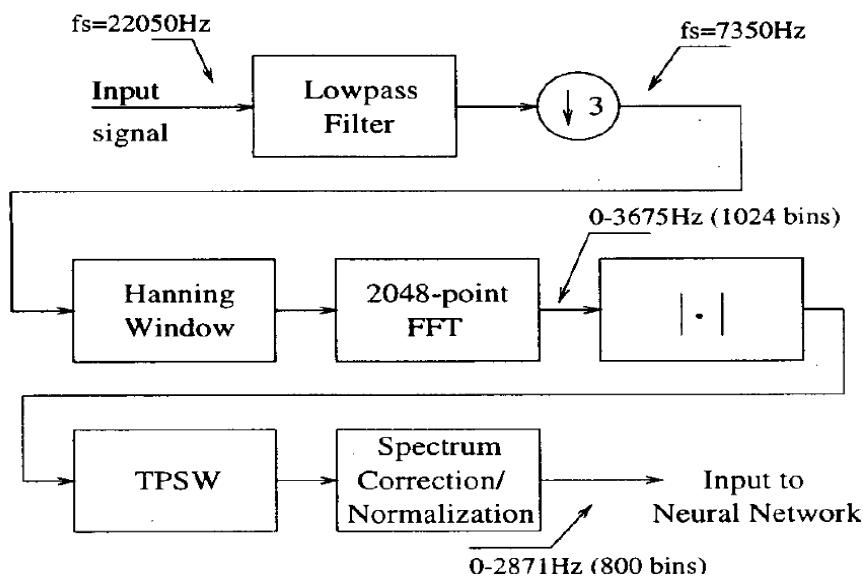
### ۲-۳- متوسط گیری طیفی

اساس این روش استفاده از اطلاعات بدست آمده از طیف‌های متوسط‌گیری شده در شناسایی نویز کشتی‌ها و یک شبکه عصبی جهت کلاس‌بندی می‌باشد . مراحل آن در زیر توضیح داده می‌شود [۴] .

### ۱-۲-۳- پردازش داده

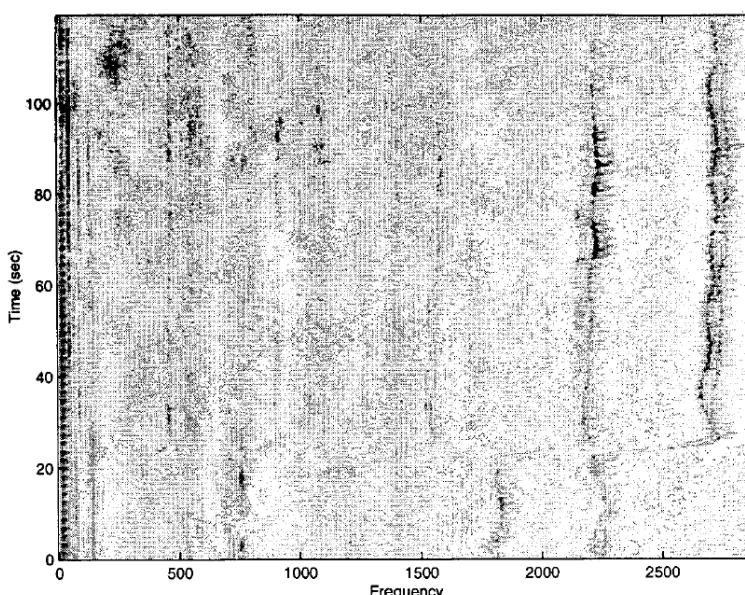
شکل ۱-۳ بلوک دیاگرام روش پردازش سیگنال به کار برده شده را نشان می‌دهد . ابتدا سیگنال فیلتر می‌شود و فرکانس نمونه‌برداری با ضریب کاهش ۳ ، کاهش می‌یابد . سپس بلوک‌هایی متوالی از ۲۰۴۸ نقطه بدون همپوشانی با یک پنجره Hanning درهم ضرب شده و توسط تبدیل فوریه سریع به حوزه فرکانس برده می‌شود [۶] . برای هر طیف بدست آمده ، ۸۰۰ بین فرکانسی معادل با یک محدوده فرکانسی از صفر تا ۲.۸۷ کیلوهرتز باقی می‌ماند . هر طیف مربوط به پنجره زمانی با مدت زمان ۲۷۸ میلی ثانیه است . گام بعدی در پردازش سیگنال تخمین نویز پس زمینه محیطی برای هر طیف ، در محل اندازه‌گیری سیگنال است . بنابراین از الگوریتم TPSW<sup>۱</sup> استفاده می‌شود که برای هر فرکانس در طیف ، معادل میانگین محلی به صورت یک تخمین از نویز پس زمینه در نظر گرفته می‌شود [۵،۸] .

<sup>۱</sup> two-pass split-window

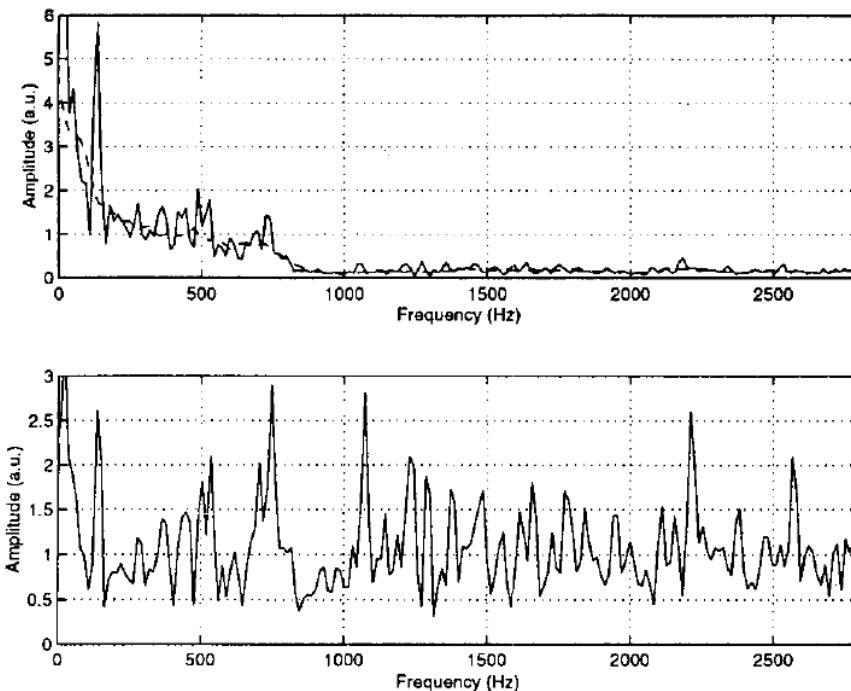


شکل ۳-۱-۳ - بلوک دیاگرام روش متوسط‌گیری طیفی اعمال شده بر سیگنال ورودی [۴]

سپس طیف توسط تقسیم دامنه در هر فرکانس با معادل آن در نویز پس زمینه تنظیم می‌گردد . شکل ۲-۳ یک اسپکتروگرام بدست آمده از یک کشتی خاص ازیک کلاس معلوم را نشان می‌دهد . ۸۰۰ نمونه در حوزه فرکانس برای هر پنجره زمانی نشان داده شده است . در اسپکتروگرام می‌توان خطوط عمودی که نشان دهنده سیگنال تولیدی توسط هر یک از ماشین آلات داخلی کشتی است را مشاهده کرد . شکل ۳-۳ تأثیر کاربرد روش TPSW را نشان می‌دهد . تصحیح‌سازی با استفاده از TPSW متوسط محلی یا همان نویز پس زمینه را حذف و همزمان طیف را نرمالیزه می‌کند .



شکل ۳-۲-۳- اسپکتروگرام کشتی با کلاس معلوم [۴]



شکل ۳-۳- (الف) طیف متوسط حاصل از اسپکتروگرام شکل ۲ (ب) همان طیف بعداز تصحیح [۴] TPSW سازی با استفاده از روش

### ۲-۲-۳- متوسط‌گیری داده :

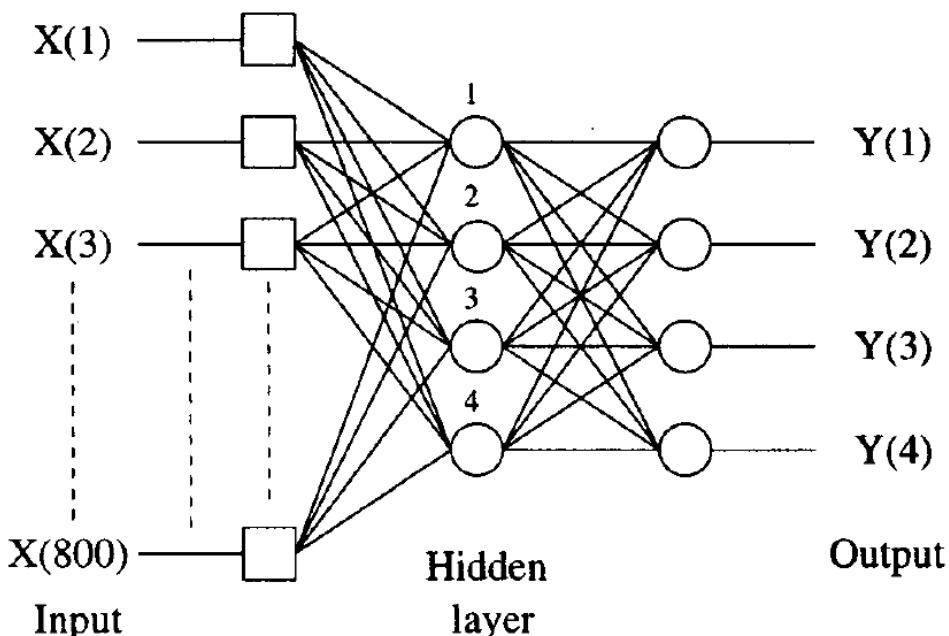
در این مورد نویز تولیدی توسط ماشین آلات و پروانه یک کشتی را بدون تغییر در سرعت و شرایط ماشین‌آلات آن می‌توان به صورت یک فرآیند تصادفی ایستا در نظر گرفت [۷]. از آنجایی که نویز کلی تولیدی کشتی نیز ترکیبی از این منابع می‌باشد، می‌توان نویز کلی را نیز ایستا در نظر گرفت. برای یک نویز تصادفی ایستا، استفاده از متوسط طیف سیگنال به نویز را افزایش می‌دهد.

در این کار برای حل مسئله کلاس بندی استفاده از اطلاعات طیف متوسط‌گیری شده برای آموزش و تست یک کلاسیفایر عصبی پیشنهاد می‌شود. فرآیند متوسط گیری توسط تعدادی از طیفهای متوالی بدون انطباق انجام می‌شود. برای مثال اطلاعات متوسط سه طیف ۱، ۲ و ۳ با استفاده از متوسط‌گیری به صورت طیف متوسط‌گیری شده ۱ در نظر گرفته می‌شود. در حالیکه متوسط طیف‌های ۴، ۵ و ۶ به صورت طیف متوسط‌گیری شده ۲ و الی آخر.

### ۳-۲-۳- کلاسیفایر عصبی

اطلاعات طیف متوسط گیری شده برای آموزش یک کلاسیفایر عصبی بر اساس یک شبکه عصبی پیشخورد استفاده می شود . شکل ۴-۳ شبکه عصبی را نشان می دهد . شبکه عصبی دارای ۳ لایه با ۸۰۰ گره ورودی ، ۴ گره در لایه مخفی و ۴ گره خروجی است . ۴ گره لایه مخفی توسط آنالیز جداسازی ساخته می شوند [۵] . هر گروه خروجی به یک کلاس خاص اختصاص می یابد . شبکه توسط الگوریتم یادگیری پس انتشار خطا با نرخ یادگیری منطبق با خطای خروجی آموزش داده می شود . مقادیر موردنظر منطقی، ۱ برای گره فعال و -۱ برای گره غیر فعال استفاده می شود . تمام نرونها تابع تانژانت هایپر بولیک را به عنوان تابع فعال‌ساز به کار می‌برند .

ماکریم احتمال برای تعیین کلاس اختصاص داده شده توسط کلاسیفایر به طیف ورودی شبکه استفاده می‌شود . بنابراین خروجی با بالاترین مقدار فعال سازی کلاس انتخابی برای یک طیف ورودی معلوم را مشخص می‌کند . کارایی کلاس بندی به صورت درصد طیفهای تمام کلاس هایی است که به صورت صحیح کلاس بندی شده‌اند .



شکل ۴-۳ ساختار شبکه عصبی [۴]

### ۳-۳- کاربرد شبکه عصبی احتمالی<sup>۲</sup> با چندین مقدار پراکندگی در کلاس‌بندی نویز کشتی

#### ۱-۳-۳ - مقدمه

چندین نوع از شبکه‌های عصبی برای کاربردهای کلاس‌بندی استفاده می‌شوند، اما PNN معمولاً بدليل مزایای آن به کار می‌رود. PNN یک شبکه عصبی پیشخورد با روش یادگیری با ناظری است که از قانون تصمیم‌گیری بیز و پنجره پارزن استفاده می‌نماید. PNN دارای مزایای زیر است :

- سرعت آموزش سریع : PNN ۵ برابر سریعتر از BP است .

- همگرایی تضمین شده برای کلاسیفایر بیز اگر داده آموزشی کافی فراهم گردد .

- قابلیت آموزشی افزایشی آن سریع است .

علی‌رغم مزایای بالا عیب PNN معمولی، انتخاب پارامتر گستردگی (پراکندگی) آن است . پارامتر PNN پراکندگی یا معیار همواری معادل با انحراف استاندارد پنجره پارزن گوسی است . کارایی خوب

بستگی به انتخاب صحیح پارامتر پراکندگی دارد . [۹]

#### ۲-۳-۳ PNN معمولی

شبکه عصبی احتمالاتی عادی یک شبکه عصبی پیشخور با نظارت می‌باشد که شامل سه لایه است: لایه ورودی ، لایه مخفی ، لایه خروجی . کاربرد این نوع از شبکه عصبی در مورد مسائلی که در آنها زمان آموزش خیلی حساس و یا مجموعه داده‌های آموزشی در دسترس خیلی کم است . ابعاد لایه ورودی را ابعاد بردار ویژگی‌های جداساز تعیین می‌کند .

---

<sup>۲</sup>Probability Neural Network (PNN)

لایه مخفی دارای  $N$  الگو و لایه خروجی دارای  $C$  کلاس است .  $N$  الگو تنها و تنها به یکی از  $C$  کلاس خروجی متصل است . شبکه عصبی احتمالاتی از قانون بیز برای تصمیم‌گیری استفاده می‌کند که یعنی شبکه عصبی احتمالاتی ،  $w_i$ (کلاس  $i$ ) را انتخاب می‌کند اگر

$$p(\mathbf{x}|w_i)P(w_i) > p(\mathbf{x}|w_j)P(w_j) \quad j = 1, \dots, C, j \neq i \quad (1-3)$$

که  $\{\mathbf{x} = \{x_1, x_2, \dots, x_d\}$  یک بردار ویژگی  $d$  بعدی و  $P(w_i)$  و  $p(\mathbf{x}|w_i)$  به ترتیب تابع چگالی احتمال شرطی و احتمال پیشین بدست آمده از داده آموزشی برای کلاس  $i$  هستند .  $P(w_i)$  برای  $i=1,2,\dots,C$  به صورت زیر بدست می‌آید :

$$P(w_i) = \frac{\text{تعداد داده آموزشی کلاس } i}{\text{کل داده‌های آموزشی}} \quad (2-3)$$

و  $P(X|w_i)$  توسط پنجره پارزن تخمین زده می‌شود . روش ( هسته ) پارزن یک روش غیرپارامتریک برای تخمین تابع چگالی احتمال است . در این روش ، یک پنجره  $d$  بعدی متقارن که معمولاً یک پنجره گوسی است روی مرکز هر داده های آموزشی قرار داده می‌شود . پنجره کلاس  $i$  روی داده های این کلاس قرار داده و نرمال‌سازی می‌شود .

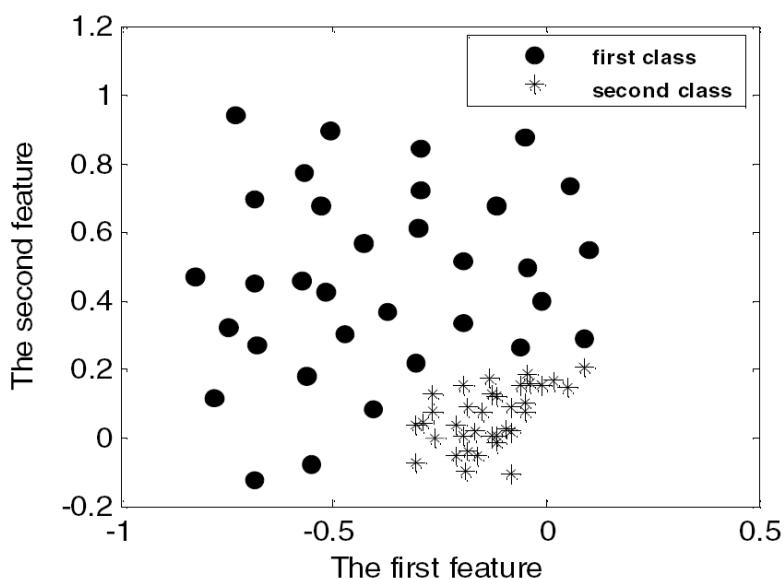
PNN معمولی نیاز به یک پارامتر ورودی پراکندگی دارد . این پارامتر توسط کاربر انتخاب می‌شود . انحراف استاندارد پنجره پارزن گوسی متناسب با پارامتر پراکندگی است و برای تمام نمونه ها در تمام کلاس ها یکسان است . مهمترین عیب PNN معمولی در دشوار انتخاب مقدار پراکندگی مناسب است . کارآمدی طبقه بندی شدیداً وابسته به انتخاب یک مقدار پراکندگی مناسب است . مقادیر پراکندگی خیلی کوچک یک تابع چگالی احتمال میله ای می‌دهد و مقادیر خیلی بزرگ جزئیات را هموار می‌کند . همچنین برخی روشها همانند روش Cross-validation برای تخمین مقدار پراکندگی مناسب وجود دارد اما انها نیاز به زمان پردازش بالایی دارند . بنابراین ، پارامتر پراکندگی معمولاً توسط سعی

و خطای تعیین می‌شود . دیگر عیب PNN معمولی استفاده از همان پارامتر پراکندگی برای تمام کلاس‌هاست که درجه آزادی تخمینگرتابع چگالی احتمال را کاهش می‌دهد . برای از بین بردن این معایب ، PNN دارای چندین مقدار-پراکندگی که پارامتر پراکندگی متفاوت برای هر کلاس استفاده می‌کند و همچنین یک روش جدید برای برآورد پراکندگی پیشنهاد می‌شود .

### ۳-۳-۳-۳ PNN دارای چندین مقدار پراکندگی و روش جدید برآورد پارامتر پراکندگی

#### ۱-۳-۳-۳ PNN دارای چندین مقدار پراکندگی

یک مسئله کلاس بندی نمونه با دو ویژگی جداسازی را در شکل ۳-۵ مشاهده می‌کنید . همانطور که در این شکل نشان داده می‌شود ، نمونه‌های کلاس اول نسبت به نمونه‌های کلاس دوم دورتر از یکدیگرند . بدیهی است ، پارامتر پراکندگی مناسب برای کلاس اول متفاوت را پارامتر پراکندگی مختص برای کلاس دوم است . بنابراین به کار بردن یک PNN با چندین مقدار پراکندگی به جای PNN معمولی مطلوب است .



شکل ۳-۵- نمودار پراکندگی یک نمونه کلاس‌بندی [۹]

PNN دارای چندین مقدار پراکنده‌گی، یک شبکه عصبی احتمالی است که قادر به تخمین تابع چگالی احتمال، داده‌های آموزشی از طریق پنجره پارزن گوسی با پارامتر پراکنده‌گی متفاوت برای هر کلاس است. پارامتر پراکنده‌گی برای هر کلاس درجه آزادی شبکه عصبی را یک درجه افزایش می‌دهد و بنابراین PNN دارای چندین مقدار پراکنده‌گی انعطاف پذیرتر از PNN معمولی است.

### ۲-۳-۳-۳- روشن تخمین پارامترهای پراکنده‌گی با داده‌های آموزشی

آشکار است که مقدار اختصاصی پارامتر پراکنده‌گی هر کلاس بستگی به فاصله میان نمونه‌های مجاور آن کلاس دارد.  $D_i$  به عنوان مجموعه فواصل میان نمونه‌های کلاس  $\text{آم}$  و نزدیکترین همسایه‌شان در ان کلاس تعریف می‌کنیم:

$$D_i = \{\min \{ \text{dist} (S_k, S_j) : j = 1, \dots, N_i, j \neq k \}; K = 1, \dots, N_i; i = 1, \dots, c\} \quad (4-3)$$

- $\text{dist}(S_k, S_j)$  فاصله اقلیدسی میان دو نمونه  $S_k$  و  $S_j$  است.  $N_i$  تعداد نمونه‌های کلاس  $\text{آم}$  و  $c$  تعداد کلاس‌هاست. بدیهی است که  $D_i$ ،  $N_i$  عضو دارد. چندین روش را برای بدست آوردن یک مقدار مناسب پارامتر گستره‌گی از  $D_i$  را امتحان شد. برای مثال، کوچکترین عضو  $D_i$  متوسط عضوهای  $D_i$  میانه عضوهای  $D_i$ ، بزرگترین عضو  $D_i$  و یک ترکیب خطی از این پارامترها به عنوان یک مبدأ انتخاب مقدار پارامتر پراکنده‌گی در نظر گرفته شد. با استفاده از شبیه‌سازی دریافتیم که معمولاً  $x \times \text{median}(D_i)$  مناسب ترین تخمین پارامتر پراکنده‌گی است که  $x$  یک عدد حقیقی در محدوده  $[1.5]$  داده‌ها شبیه‌سازی شده جهت مقایسه کارآمدی کلاس بندی PNN معمولی با یک مقدار مناسب پارامتر پراکنده‌گی و PNN دارای چندین مقدار پراکنده‌گی با پارامتر پراکنده‌گی تخمینی و  $x \in [1.5]$  به کار برده شد.

### ۳-۳-۳-۳- ویژگیهای جداسازی نویز کشتی ها

شش ویژگی زیر رابرای جداسازی کلاسهای بانک داده توصیفی قبل انتخاب شده‌اند :

- مقدار متوسط چگالی طیف توان<sup>۳</sup> نرمالیز شده
- میانه چگالی طیف توان نرمالیز شده
- فرکانس ماکزیمم مقدار چگالی طیف توان
- نسبت ماکزیمم مقدار چگالی طیف توان به توان کل
- تعداد بین‌های فرکانسی که مقدار آنها پیش از ۱۵٪ ماقزیمم مقدار است.
- بالاترین فرکانس که مقدار چگالی طیف توان آن از ۱۵٪ مقدار ماکزیمم چگالی طیف توان بیشتر است.

در تمام ویژگیهای بالا، چگالی طیف توان تخمینی با استفاده از پنجره Hamming و FFT ۱۰۲۴ نقطه‌ای همپوشانی ۵٪ است. نرمالیز کردن چگالی طیف توان با تقسیم چگالی طیف توان تخمینی بر ماکزیمم مقدار آن انجام شده است. بعد از استخراج ۶ ویژگی از بانک داده، هر مجموعه ویژگی با استفاده از ماکزیمم مقدار آن نرمالیز می‌شود. تمام ویژگیهای ذکر شده توسط نویسنده انتخاب شده غیر از ویژگی سوم که در [۱۰] ذکر شده است.

---

<sup>۳</sup>Power Spectral Density (PSD)

### ۴-۳-۳- بانک داده صوتی مورد استفاده در روش شبکه عصبی احتمالاتی

مجموعه داده‌ها متشکل از کشتی‌های سنگین شامل ۲۹ فایل نویز انتشاری از پنج کشتی تجاری مختلف، مجموعه داده‌های کشتی‌های متوسط متشکل از ۲۶ فایل از سه کشتی متوسط و مجموعه داده قایق‌ها شامل ۱۶ فایل از ۴ قایق می‌باشد. معیار اصلی برای تقسیم‌بندی این کشتی‌ها به این کلاسها سایز و وزن آنها است. تمام فایل‌ها در خلیج فارس در موقعیت‌های دریابی کم‌عمق ثبت شده است. طول زمان فایل ۵ ثانیه و فرکانس نمونه برداری ۲۵۶۰ نمونه بر ثانیه است. تمام فایلهای داده محتوی تنها باند فرکانسی ۱۲۵ تا ۵۰۰ هرتز می‌باشند.

### ۴-۳- تبدیل موجک برای کلاس‌بندی عصبی

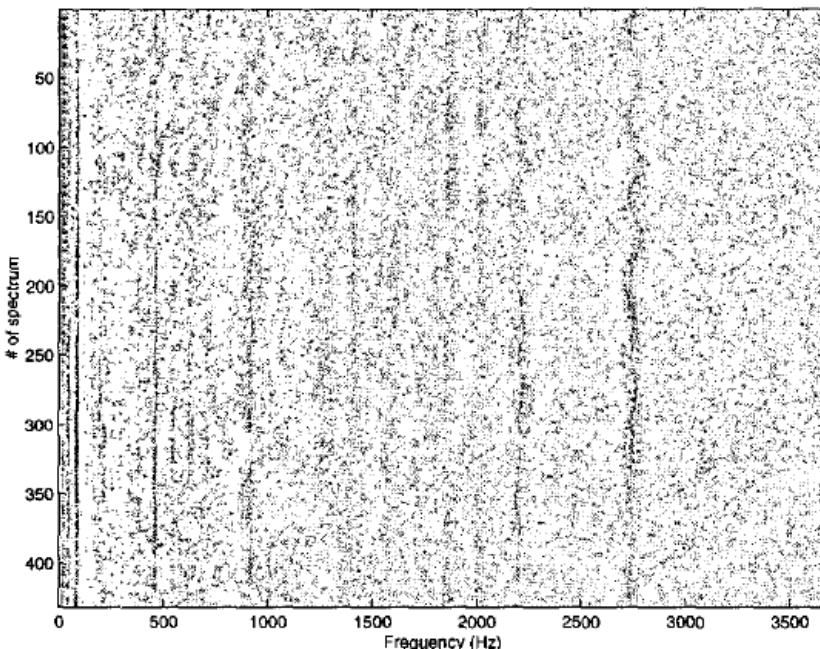
#### ۱-۴-۳- مقدمه

در این روش تبدیل موجک سیگنال ورودی را در چندین مرحله پیاپی محاسبه می‌نماید. آنگاه تمامی خروجی‌های فرکانس پایین هر مرحله وارد یک شبکه عصبی جهت کلاس‌بندی می‌شوند. شرح روش در زیر آمده است. [۱۱]

#### ۲-۴-۳- پردازش داده

در این تحقیق یک روش پیش‌پردازش در حوزه فرکانس جهت بهینه کردن کارایی کلاسیفایر پیاده می‌شود. محدوده فرکانسی انتخابی جهت آنالیز از  $DC$  تا حدود ۲.۵ کیلوهرتز است، زیرا این محدوده بیشترین اطلاعات وابسته به قسمت فعالیت موتورخانه‌ای در کشتی‌های موردنظر معلوم برای طبقه بندی شامل می‌شود. به این دلیل سیگنال دیجیتال شده توسط فیلتر پایین گذر فیلتر و ضریب کاهش ۳، کاهش نمونه شده و فرکانس نمونه برداری به ۷.۳۵ کیلو هرتز تقلیل می‌یابد. فیلتر مورد کاربرد یک فیلتر پایین گذر نوع یک چیشف مرتبه ۸ با باند گذر ۲.۸۷ کیلوهرتز و ضریب میرایی

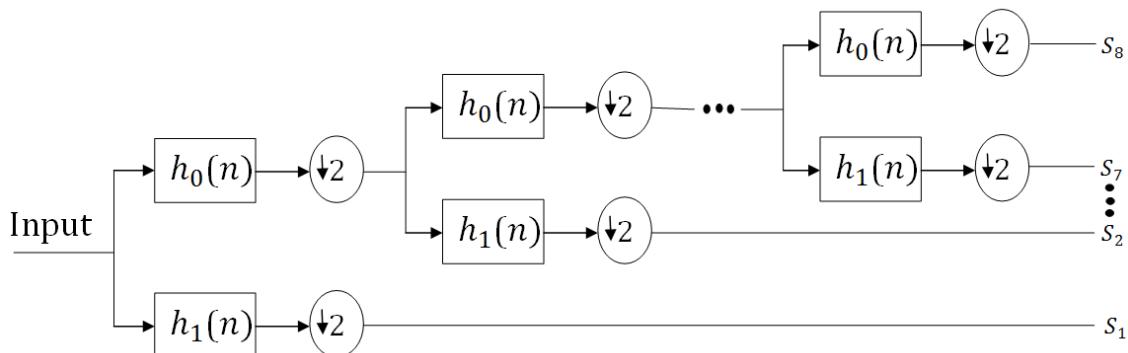
۰۶دیبل در فرکانس ۴.۴۸ کیلوهرتز جهت اطمینان از نبود تأثیر همپوشانی<sup>۴</sup> می باشد . سیگنال های سونار بدلیل حرکت نسبی میان کشتی و سنسور و هم چنین تغییرات شرایط انتشار در محیط زیر آب به آهستگی تغییر می کنند . علیرغم این تغییرات سیگنال دریافتی برای پنجره زمانی با طول مدت چند ثانیه به صورت یک فرآیند ایستای عریض است[۱۳] . جهت کلاس بندی از آنالیز طیفی استفاده شده است[۱۴] . شکل ۳-۶ یک اسپکتروگرام بدست آمده از یک کشتی باکلاس معلوم را نشان می دهد . ۴۰۰ نمونه در حوزه فرکانس برای هر پنجره با مدت زمان ۲۷۸ میلی ثانیه نشان داده شده است . در این اسپکتروگرام خطوط عمودی نشان دهنده سیگنال تولیدی ماشین آلات داخلی کشتی است . استفاده از تبدیل موجک برای ساختار سیگنال های دریافتی از نظر کلاس بندی مناسب است . موجک ها ، توابعی هستند که انرژی آنها در یک فاصله زمانی متمرکز شده و برای آنالیز پدیده های گذرا ، غیرایستا یا متغیر با زمان بسیار مناسبند [۱۵] .



شکل ۳-۶- اسپکتروگرام طیف کشتی باکلاس معلوم [۱۱]

برای بررسی این روش ، تبدیل موجک روی سیگنال کاهش نمونه داده شده اعمال می شود . شکل ۷-۳ ساختار بانک فیلتر مورد کاربرد برای اعمال تبدیل موجک را نشان می دهد . نمودهای هر خروجی بانک ( $S_1$  تا  $S_8$ ) طبق کاهش مربوطه تولید می شوند . بنابراین هنگامی که یک نمونه در خروجی آهسته ترین فیلتر پایین گذر ( $S_8$ ) یا آهسته ترین بالاگذر ( $S_7$ ) ایجاد می شود ، ۲ نمونه در  $S_6$  و  $S_5$  و تا ۶۴ نمونه در  $S_1$  ایجاد می شود .

اطلاعات فرکانس پایین مربوط به ماشین آلات داخلی کشتی به منظور شناسایی کاملاً مناسبند . بنابراین ، نمونه های خروجی از فیلترهای آنالیز باید بطريقی گروه بندی شوند که این اطلاعات مد نظر باشند . از اینرو ، باید تعداد محدودی از نمونه ها برای ایجاد اطلاعات تغذیه گره های ورودی شبکه عصبی باقی بمانند .



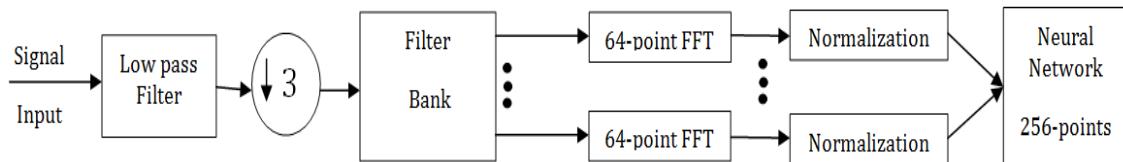
شکل ۷-۳- بانک فیلتر [۱۱]

نمودهای گروه بندی شده از طریق بانک فیلتر ، مورد آزمایش قرار گرفته اند . برای آهسته ترین خروجیها،  $S_8$  و  $S_7$  نمونه باقی ماند . هنگامی که ۶۴ نمونه در این آهسته ترین خروجی ها ایجاد شد، دیگر خروجی ها تعداد بیشتری از نمونه ها را طبق نرخ نمونه برداری بالاتر خودشان تولید کرده بودند . بنابراین ، برای باقی ماندن یک مقدار ثابت ۶۴ نمونه در ۸ خروجی بانک فیلترها ، برخی نمونه ها باید حذف شوند و بالاترین نرخ ، بالاترین حذف نمونه های خروجی را دارد . برای مثال  $S_8$  ،  $S_7$  نمونه برای هر ۶۴ نمونه موجود در  $S_8$  یا  $S_7$  تولید می کند ، بنابراین از هر دو نمونه  $S_6$  تنها باید یکی

باقي بماند و الی آخر . با انجام این ، نمونه های فرکانس پایین تر به طور کامل باقی می ماند و اطلاعات فرکانس بالا بر طبق اهمیت کمتر خود در کلاس بندی عمل می کند .

برای تغذیه کلاسیفایر ، اطلاعات حوزه فرکانس توسط تبدیل فوریه سریع ۶۴ نقطه‌ای که در شکل ۸-۳ داده شده روی ۶۴ نمونه باقی مانده از هر خروجی بانک فیلتر اعمال می شود . بنابراین ، ۸ طیف ۶۴ نقطه‌ای برای هر پنجره پردازشی ، یک بردار ورودی با ۲۵۶ جزء را نتیجه می دهد . سرانجام ، یک روش نرمال سازی یا بوسیله جمع نمونه ها به عنوان ضریب نرمال سازی یا توسط تقریب تصحیح نویز پس زمینه با استفاده از الگوریتم TPSW اعمال می شود .

ترکیب نمونه های مذکور ، تعداد زیادی از نمونه های خروجیها با نرخ نمونه برداری بالا را حذف می کند . روش جایگزین ، کار با طیف متوسط‌گیری شده و استفاده از اطلاعات قابل دسترسی از هر گره خروجی است . اگر تعداد نمونه ها در ۶۴ ثابت بماند ، خروجیهای  $S_7$  و  $S_8$  یک طیف ۶۴ نمونه‌ای ایجاد می کنند در حالیکه برای مثال  $64 \times 64$  طیف در خروجی  $S_1$  است و می تواند برای تولید طیف ۶۴ نمونه‌ای متوسط‌گیری می شود و به ورودی کلاسیفایر اعمال شود .



شکل ۳-۸-۳- نمودار پردازش [۱۱]

### ۳-۴-۳- کلاس بندی عصبی

طیف پیش پردازش شده جهت آموزش و تست کلاسیفایر عصبی به کار رفت [۱۲] . کلاسیفایر عصبی یک شبکه عصبی پیشخورد تمام اتصال متشکل از ۲۵۶ گروه ورودی، یک لایه مخفی با ۱۶ نرون و ۴ نرون در لایه خروجی است . هر ۴ نرون خروجی به یک کلاس تخصیص می یابد . تمام نرونها از نوع

تائزانت هایپر بولیک می باشند . شبکه عصبی بوسیله الگوریتم پساننتشار آموزش داده می شود . مقادیر باینری به گره های خروجی ، ۱ برای گره فعال و ۰ برای گره های غیرفعال باقی مانده ، اختصاص می یابد .

طیف محاسبه شده از هر داده عملی به دو بخش آموزشی و آزمایشی تقسیم شد. بعلاوه داده های آموزشی (۶۲۰۰ طیف) به دو مجموعه آموزشی و validation تقسیم شد [۱۲] . تعداد فردی از طیف های آموزشی، مجموعه آموزشی و تعداد زوجی از طیف های آموزشی، مجموعه validation را تشکیل می دهند . مجموعه validation معیاری برای تعیین توقف مرحله آموزش کласیفایر است . طیف های مجموعه آموزشی برای تطبیق کارایی کلاس بندی از طریق مجموعه validation در یک فرکانس آموزشی معین ارزیابی می شود . مجموعه وزنهای مرحله آموزشی با کارایی کلاس بندی بالا در طیف های مجموعه validation جهت فاز تولید ذخیره می گردد . قابلیت کلاس بندی حاصل از طیف آزمایشی در فاز آموزشی سهیم نبوده بنابراین قادر به تست ویژگی عمومی کласیفایر است . ماکزیمم احتمال جهت تعیین کلاس اختصاص داده شده بوسیله کласیفایر به یک طیف ورودی استفاده می شود . قابلیت کلاس بندی کلی از طریق درصد طیف تمام کلاس های درست کلاس بندی شده در مجموعه آزمایشی بدست می آید .

### ۳-۵- شناسایی کشتی از طریق روش‌های مبتنی بر فراکتال<sup>۵</sup>

#### ۱-۵-۳ مقدمه

واژه فراکتال توسط بندیت مندلبورت در سال ۱۹۷۵ بوجود آمد . این لغت از کلمه لاتین Fractus به معنای شکسته گرفته شده است . به طور کلی فراکتال‌ها را موجوداتی ریاضی می‌دانند به دلیل آنکه نشان داده شده است ، بسیاری از وضعیت‌هایی را که نمیتوان با هندسه اقلیدسی توضیح داد به راحتی توسط فراکتال‌ها بیان می‌شوند .

ساده‌ترین نوع فراکتال ، فراکتال کانتور است . پاره‌خطی به واحد را در نظر بگیرید ، آنرا به سه قسمت مساوی تقسیم کرده و سپس قسمت میانی را حذف نمایید . اکنون دو پاره‌خط با یک سوم طول اولیه داریم . این عمل را برای هر یک از این پاره‌خط‌ها تکرار می‌کنیم . اگر این عمل رل به تعداد بی‌نهایت انجام دهیم شکلی به‌دست می‌آید که مجموعه کانتور نام دارد . مجموعه کانتور ساختاری است که تا بینهایت ادامه دارد و در عین حال کاملاً شبیه شکل کلی است .

اما روش‌های مبتنی بر فراکتال شامل حرکت براونی فراکتال<sup>۶</sup> ، آنالیز بعد فراکتال و آنالیز موجک است . تمرکز اصلی مطالعات فراکتال اینست که آیا اصوات کشتی ، سیگنال‌های فراکتال هستند . در وضعیت‌های پیچیده از نقطه نظر ریاضی شاید اصوات کشتی عیناً به صورت سیگنال‌های  $\frac{1}{f}$  رفتار نکنند ، اما از نقطه نظر مهندسی ، شباهت مشهودی میان طیف صوت کشتی و سیگنال‌های  $\frac{1}{f}$  است .

---

<sup>۵</sup>fractal

<sup>۶</sup>fractal Browning motion

بواسطه آزمایشات گسترده ، Urick دریافت که طیف توان صوت کشتی در فرکانس های بالا ۶

دستیبل بر اکتاو کاهش می یابد . این ویژگی همانند ویژگی سیگنالهای  $\frac{1}{f}$  است .

برای کلاس بندی پیشنهادی ، کافی است طول طیف صوت کشتی شبیه به سیگنالهای  $\frac{1}{f}$  باشد [۱۷] .

بوسیله آزمایشات نشان داده می شود که اصوات کشتی را می توان توسط روش های فراکتال بطور

مناسبی کلاس بندی کرد . در عوض سیگنالهای سونار فعال را نمی توان با استفاده از ویژگی های فراکتال

کلاس بندی کرد چرا که طیف آنها بطور مشخص متفاوت از سیگنالهای  $\frac{1}{f}$  است . روش های فراکتال

توصیفی دارای قابلیت های : (۱) قاعده مند نمودن صوت کشتی در یک روش جدید (۲) ایجاد برخی

اطلاعات که توسط ویژگی های مرسوم ایجاد نمی شوند (۳) بهتر کردن شناسایی کشتی می باشند . این

روش ویژگی های مورد نظر را از طریق روش مبتنی بر فراکتال استخراج نموده و با کلاسیفایر

ماهالانوبیس داده ها ورودی جدید را کلاس بندی می نماید [۱۶] .

### ۳-۵-۲- کلاسیفایر

فرض می کنیم . که M کلاس  $H_1$  و  $H_2$  و ....  $H_m$  وجود دارد و هر کلاس متشکل از بردارهایی با  $2N$

ویژگی هستند .  $S_i = \{V_{i,1}, V_{i,2}, \dots, V_{i,N}\}$  و  $T_i = \{U_{i,1}, U_{i,2}, \dots, U_{i,N}\}$  به ترتیب N نمونه آموزشی

و N نمونه تست قرار می دهیم که بطور تصادفی از  $H_i$  انتخاب می شوند و

$$T_i \cup S_i = H_i, T_i \cap S_i = \emptyset$$

بردار متوسط  $T_i$  تعریف به صورت زیر تعریف می شود :

$$\mu_i = \frac{1}{N} \sum_{j=1}^N U_{i,j} \quad (5-3)$$

در مرحله آموزش  $\{\mu_i | i = 1, \dots, M\}$  باید محاسبه شود . در مرحله تست

فاصله  $D(V_{i,j}, V_k)$  باید محاسبه شود که  $\{D(V_{i,j}, V_k) | k = 1, 2, \dots, D_2 = 1, \dots, M, j = 1, 2, \dots, N\}$

ماهالانوبیس میان  $V_{ij}$  و  $M_k$  است. اگر  $l = \arg \min_K \{D(V_{i,j}, V_k)\}$  باشد می توان  $V_{ij}$  را متعلق دانست [۱۸].

### ۳-۵-۳- حرکت براونی فراكتال تحلیلی

طیف توان صوت کشتی همانند حرکت براونی فراكتال در فرکانس های بالا ۶ دسیبل برآکتاو کاهش می یابد [۱]. این شباهت، کاربرد ابزار آنالیز حرکت براونی فراكتال را جهت آنالیز صوت کشتی مجاز می نماید. (  $B_H(t)$  یک حرکت براونی فراكتال دارای پارامتر  $H$  را مشخص می کند. دنباله تفاضلی  $B_H(t)$  در قانون  $T^H$  صدق می کند [۱۹].

$$\delta_K = \sqrt{\text{var}[B_H(t + K\Delta) - B_H(t)]} = C_H(K\Delta)^H \quad (6-3)$$

$\Delta$  نمایانگر فاصله نمونه برداری،  $K$  گامهای تشکیل دنباله تفاضلی  $C_H(B_H(t + K\Delta) - B_H(t))$  را می توان در صورت معلوم بودن  $H$  ثابت در نظر گرفت. قرار می دهیم:

$$H_K = [\log \delta_{K+1} - \log \delta_K] / [\log(K+1) - \log K] \quad (7-3)$$

با جایگزینی معادله ۶-۳ در معادله  $H_K = H$ ،  $H$  حاصل می شود.  $H$  متمایز معادل با مدل حرکت براونی فراكتال متمایز است. در مطابقت با  $H$ ،  $\{\delta_K\}$  و  $\{H_K\}$  بعنوان دو نوع از بردارهای ویژگی تعبیر می شوند. در عمل، اصوات کشتی‌ها نمی‌توانند سیگنالهای حرکت براونی فراكتال ایده‌آل باشند. بنابراین،  $H_K$  نمی‌تواند در هر گام  $K$ ، ثابت باشد و شاید  $\delta_K$  کاملاً در رابطه  $T^H$  صدق نکند. با این حال از طریق آزمایشات ثابت می شود،  $\{\delta_K\}$  و  $\{H_K\}$ ، اطلاعات اساسی برای شناسایی کشتی ایجاد می کند.

با فرض اینکه  $N$  دنباله صوت کشتی است، مقدار متوسط و انحراف استاندارد دنباله  $s_i: i = 1, 2, \dots, N$  به ترتیب به صورت زیر می باشند:

$$\mu_K = \frac{1}{N-K} \sum_{i=1}^{N-K} (s_{i+k} - s_i) \quad (8-3)$$

$$\delta_K = \sqrt{\frac{1}{N-K} \sum_{i=1}^{N-K} (s_{i+K} - s_i - \mu_K)^2} \quad (9-3)$$

با جایگزینی معادله ۹-۳ در معادله ۷-۳ ، دو بردار ویژگی  $\{H_K\}$  و  $\{\delta_K\}$  محاسبه می شوند . شکل - های ۹-۳ و ۱۰-۳ ، نمونه های صوتی  $\{H_K\}$  و  $\{\delta_K\}$  ، متعلق به شش کشتی را نشان می دهد . هم پایداری میان نمونه ها از هر کشتی یکسان و هم قابلیت تقسیم میان نمونه های متعلق به هر دو کشتی متفاوت ، در شکل های ۹-۳ و ۱۰-۳ مشاهده می شود .

#### <sup>۷</sup>-۳-۵-۳- آنالیز بعد فراکتال

یک بعد فراکتال بعنوان یک ابزار هندسی برای توصیف جزئیات شکل موج یک سیگنال به کار می رود . بعد "blanket - covering" برای استخراج ویژگی مناسب است زیرا محاسبات آن نامتغیر با شیفت سیگنال در بعد زمان و دامنه است [۲۰، ۲۱، ۲۲] . برای یک دنباله زمانی  $f(n): n=0, \dots, N$  ، یک مقیاس  $r$  برای تشکیل یک پوش بالا  $U_r(n)$  و یک پوش پایین  $L_r(n)$  انتخاب می کنیم که

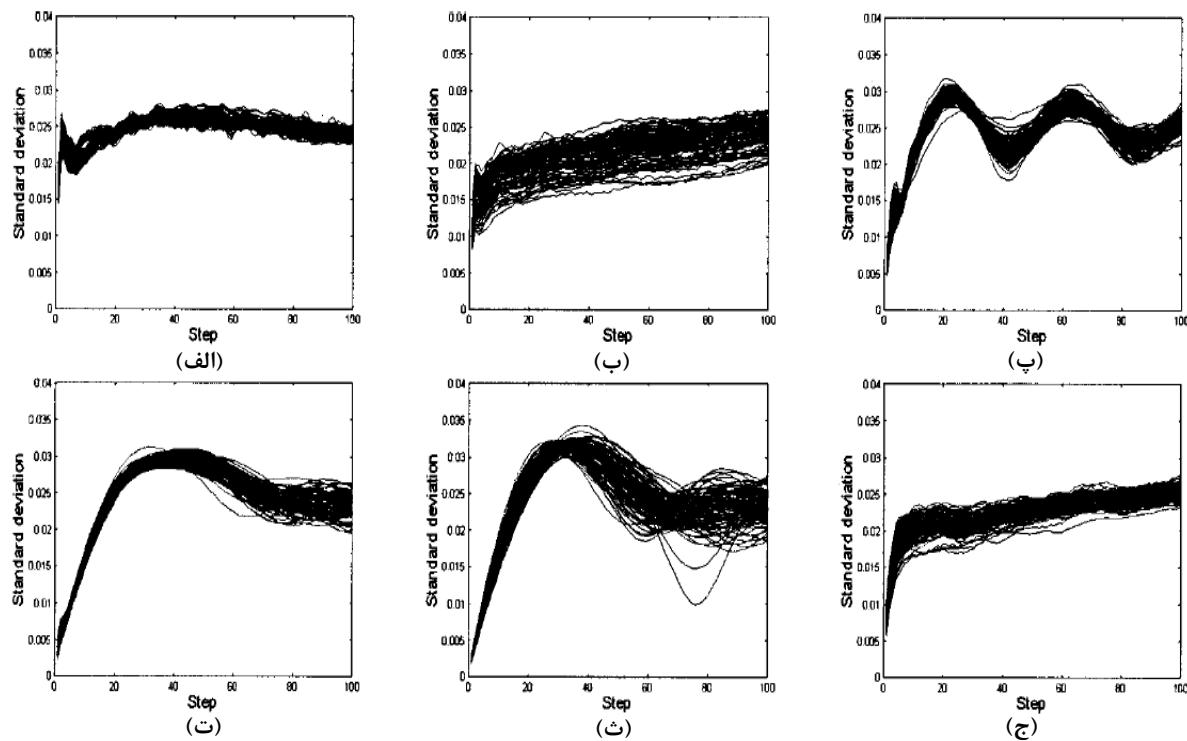
$$U_r(n) = \max \{U_{r-1}(n-1), U_{r-1}(n) + 1, U_{r-1}(n+1)\} \quad (10-3)$$

$$L_r(n) = \min \{L_{r-1}(n-1), L_{r-1}(n) + 1, L_{r-1}(n+1)\} \quad (11-3)$$

$$U_0(n) = L_0(n) = f(n) \quad (12-3)$$

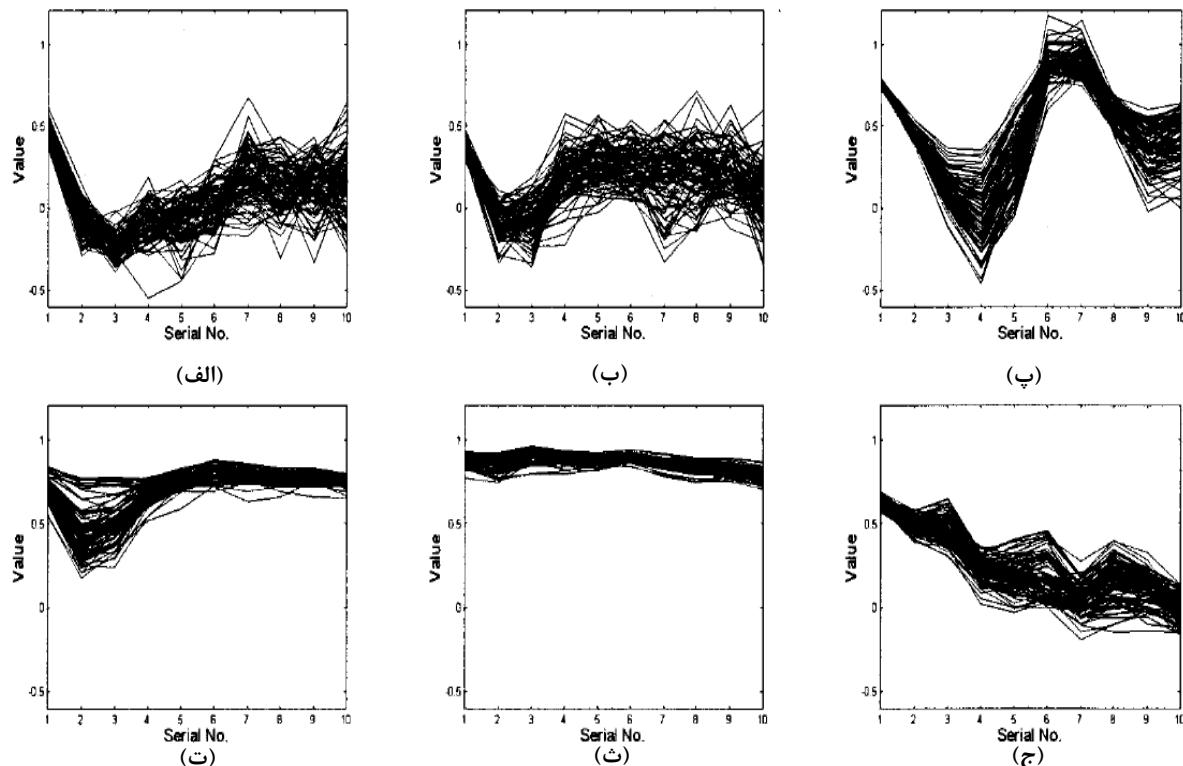
$$L(r) = \frac{1}{2r} \sum_{n=0}^N [U_r(n) - L_r(n)] \quad (13-3)$$

<sup>۷</sup>fractal dimension



شکل ۳-۹-۱۶- (الف) نمونه‌های کشتی  $\delta_k$  نمونه‌های کشتی  $A$ , (ب) نمونه‌های کشتی  $B$ , (پ) نمونه‌های کشتی  $C$

[۱۶] (ت) نمونه‌های کشتی  $D$ , (ث) نمونه‌های کشتی  $E$ , (ج) نمونه‌های کشتی  $F$



شکل ۳-۱۰-۱۰-۳ نمونه‌های کشتی  $H_k$ - (الف) نمونه‌های کشتی  $A$ , (ب) نمونه‌های کشتی  $B$ , (پ) نمونه‌های کشتی  $C$

[۱۶] (ت) نمونه‌های کشتی  $D$ , (ث) نمونه‌های کشتی  $E$ , (ج) نمونه‌های کشتی  $F$

در شرایط ایده آل،  $\log L(r)$  و  $\log L(r)$  باید در رابطه خطی زیر صدق کنند:

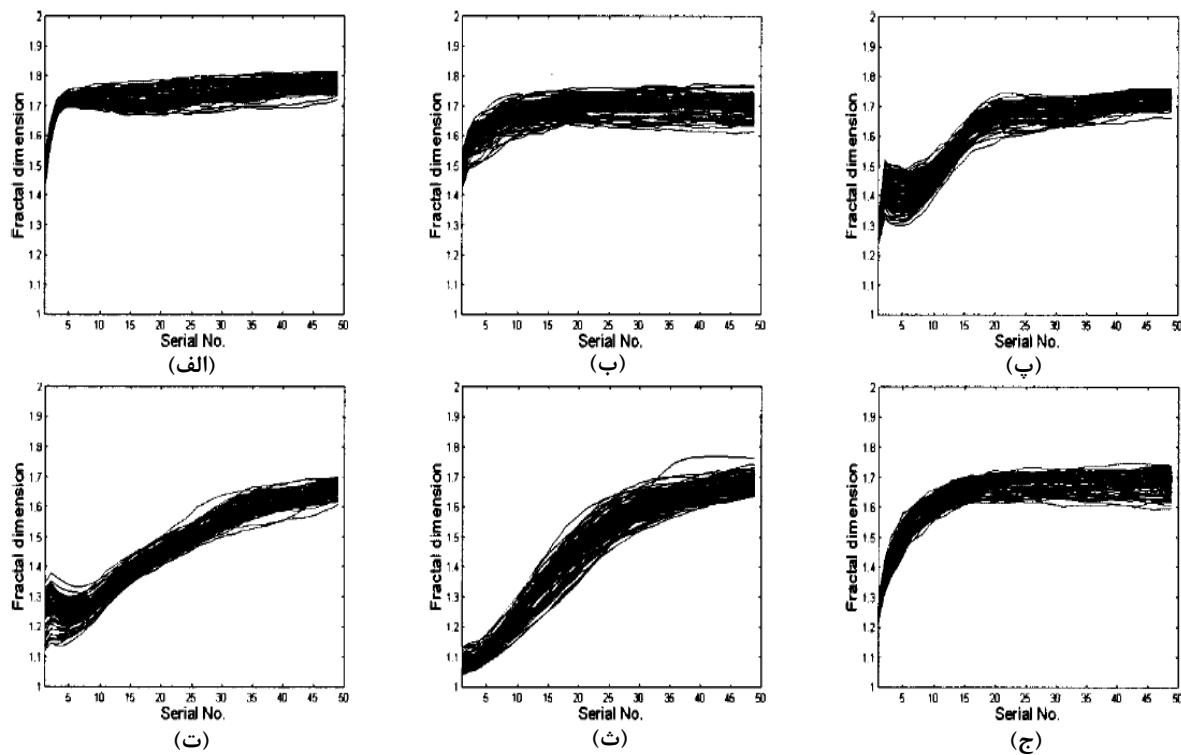
$$\log L(r) = (1 - D) \log r + \log k \quad (14-3)$$

بعد "blanket – covering" نامیده می شود و  $k$  یک ثابت است. سپس،  $D$  با منطبق کردن  $\log r$  نسبت به  $\log L(r)$  از نظر حداقل مربعات بدست می آید. در عمل،  $(\log L(r) - \log r)$  برحسب  $r$  یک خط راست نیست ولی یک منحنی هموار است. بعد فراکتال در هر مقیاسی از  $r$  ثابت نیست ازاینرو، بعد فراکتال در یک مقیاس معلوم  $r$  از طریق رابطه بدست می آید:

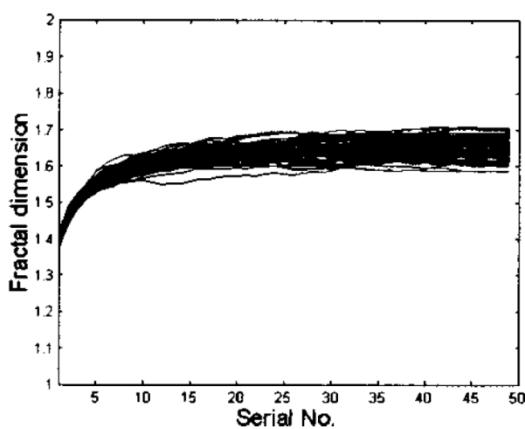
$$D_r = 1 - [\log L(r+1) - \log L(r)] / [\log(r+1) - \log(r)] \quad (15-3)$$

منشأ این معادله، معادله ۱۴-۳ است.  $D_r$  بعنوان یک نوع بردار ویژگی استفاده می شود. شکل ۳-۱۱، بعد فراکتال متعلق به نمونه های ۶ کشتی را نشان می دهد.

قابلیت تقسیم میان هر ۲ کلاس متفاوت و پایداری تولید شده داخلی میان هر کلاس یکسان، در شکل ۱۱-۳ موجود است. همچنین، بعد فراکتال ۱۰۰ نمونه حرکت براونی فراکتال با استفاده از روش فیلترینگ فوریه، در شکل ۱۲-۳ نشان داده می شود. هم در شکل ۱۱-۳ و هم در شکل ۱۲-۳، برحسب  $D_r$  در مقادیر کوچک سعودی و در مقادیر بزرگ ثابت است. همچنین مشخص می کند که  $\log L(r)$  برحسب  $\log r$  در عمل، حتی برای نمونه های حرکت براونی فراکتال یک خط راست نیست. بنابراین پیاده سازی  $\{D_r\}$  با هدف کلاس بندی منطقی است.



شکل ۱۱.۳. (الف)  $D_r$  نمونه‌های کشتی  $C$ . (ب)  $D_r$  نمونه‌های کشتی  $A$ . (پ)  $D_r$  نمونه‌های کشتی  $B$ . (ث)  $D_r$  نمونه‌های کشتی  $E$ . (ج)  $D_r$  نمونه‌های کشتی  $F$  [۱۶]



شکل ۱۲.۳  $fBm$  نمونه‌های  $D_r$  [۱۶]

#### ۴-۵-۳ - آنالیز موجک

آنالیز موجک ابزار مناسبی برای آنالیز کردن سیگنالهای  $\frac{1}{f}$  است [۲۳]. ساخت و آنالیز سیگنال  $(t)$

با استفاده از تبدیل موجک به ترتیب بیان می شود با :

$$n(t) = \sum_m \sum_j n_j^m \Psi_j^m(t) \quad (16-3)$$

$$n_j^m = 2^{j/2} \int_{-\infty}^{+\infty} n(t) \Psi_j^m(t) dt \quad (17-3)$$

$\Psi_j^m(t)$  می‌تواند بیانگر هر مبنا موجک عمود بر هم باشد و  $n_j^m$  ضرایب مقیاس  $m$  را معین می‌کند.

در محاسبات پیش رو، موجکهای چپشیف (۴ ضربان) استفاده می‌شود [۲۴]. اثبات شده است که

ضرایب موجک هر سیگنال  $\frac{1}{f}$  معلوم در توزیع گوسی میانگین-صفر صدق می‌کند. بدین معنی که

تمایز میان مدل‌های  $\frac{1}{f}$  متفاوت شامل مجموعه پارامتر  $\{\delta_m^2\}$  برای هر مدل است. تخمینگر ماکزیمم

شباهت  $: \delta_m^2$

$$\delta_m^2 = \frac{1}{N(m)} \sum_j (n_j^m)^2 \quad (18-3)$$

$N(m)$  بیانگر تعداد ضرایب موجک در مقیاس  $m$  است. مجموعه پارامتر تخمین زده شده  $\{\delta_m^2\}$ ،

ابزاری است برای تعیین مدل سیگنال که نمونه معلوم  $n(t)$  را تولید می‌کند. { $\delta_m^2$ } عنوان یک

نوع بردار ویژگی استفاده می‌شود.

### ۳-۵-۵ بانک داده استفاده شده

مجموعه داده شامل نمونه‌های صوتی بدست آمده از ۶ کشتی است. در خصوص هر کشتی، ۱۰۰

نمونه جمع آوری شد. طول هر نمونه ۳۲۶۴ است. برای تنظیم تغییر فاصله میان کشتی و دریافت-

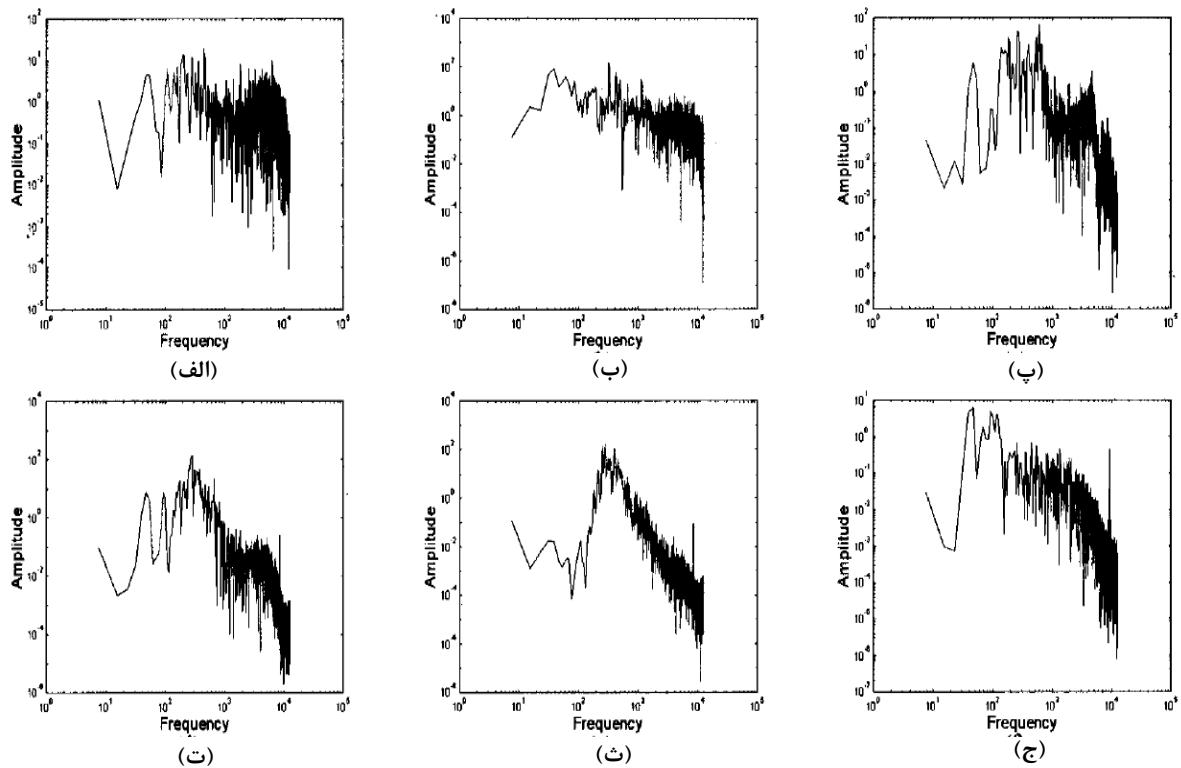
کننده، هر نمونه برای داشتن انرژی واحد به جذر انرژی خودش تقسیم می‌شود. طیف توان مصرف

نمونه‌های هر کشتی به ترتیب در نمودار  $\log - \log$  شکل ۱۳-۳ نشان داده می‌شود. شکل ۱۴-۳

نمونه طیف توان حرکت براونی فراکتال انتخاب شده از ۱۰۰ نمونه حرکت براونی فراکتال ایجاد شده

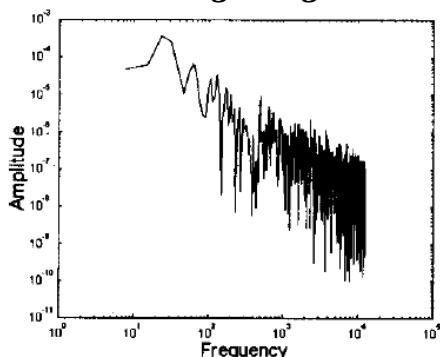
توسط روش فیلتر کردن فوریه را نشان می‌دهد. شکل ۱۳-۳ و ۱۴-۳ نشان می‌دهند که طیف نمونه

های صوت کشتی مشخصاً شبیه به نمونه حرکت براونی فراکتال است.



شکل ۱۳-۳- (الف) طیف توان نمونه کشتی  $A$  در نمودار  $\log - \log$ ، (ب) طیف توان نمونه کشتی  $B$  در نمودار  $\log - \log$ ، (پ) طیف توان نمونه کشتی  $C$  در نمودار  $\log - \log$ ، (ت) طیف توان نمونه کشتی  $D$  در نمودار  $\log - \log$ ، (ث) طیف توان نمونه کشتی  $E$  در نمودار  $\log - \log$ ، (ج) طیف توان نمونه کشتی  $F$  در نمودار  $\log - \log$

#### [۱۶] $\log - \log$



شکل ۱۴-۳ = طیف توان نمونه  $fBm$  در نمودار [۱۶]  $\log - \log$

### ۳-۶- الگوریتم ترکیبی چند کلاسیفایر

#### ۱-۶-۳ مقدمه

این روش ویژگی‌های مشخصه را توسط چندین روش مهم در پردازش گفتار استخراج و توسط دو کلاسیفایر SVM و BPNN طبقه‌بندی می‌کند. این روش دارای مراحل زیر است : [۲۴]

#### ۲-۶-۳ مدل ترکیبی و جزئیات الگوریتم

#### ۱-۲-۶-۳ مدل ترکیبی از کلاسیفایر های چند گانه :

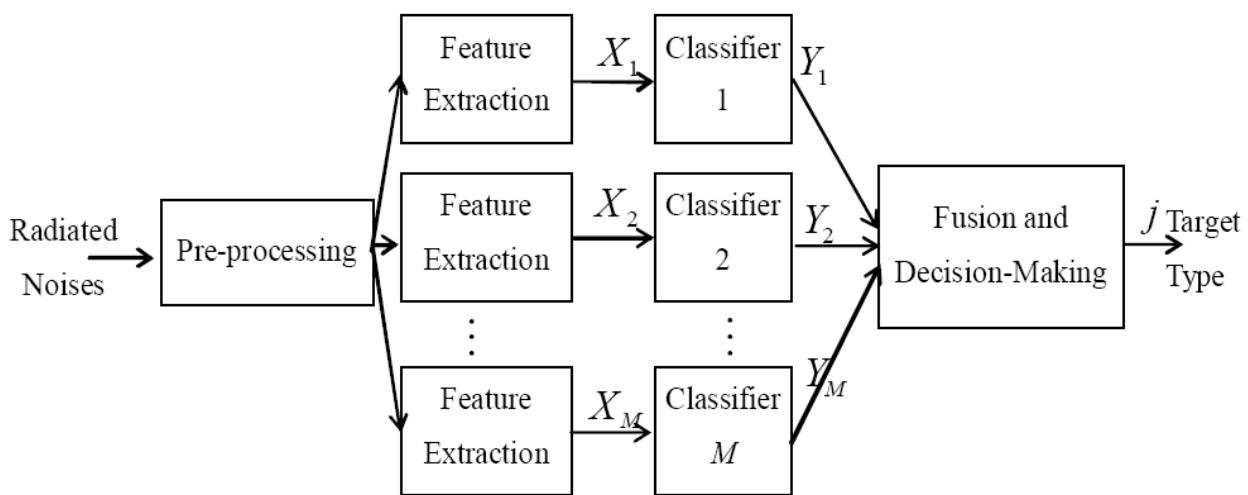
مدل ترکیبی از کلاسیفایر های چند گانه در شکل ۳-۱۵ نشان داده می شود . بر طبق مدل، در آغاز ، نویز انتشاری کشتی ها پیش پردازش می شوند . بنابراین انواع روش‌های استخراج ویژگی متفاوت و کلاسیفایرها تک متفاوت را انتخاب می کنیم و پس بردارهای خروجی از تمام کلاسیفایرها را توسط ترکیب و مرکز تصمیم گیری ترکیب می شوند و سپس نوع هدف درست، نشان داده می شود.

سیستم از  $M$  کلاسیفایر تشکیل می شود. بردار خروجی کلاسیفایر  $\text{آم}$ ،  
 $y_i = (y_i^1, y_i^2, \dots, y_i^j, y_i^N)$  کلاسیفایر  $i$  به هدف  $j$  است ، به معنای دیگر وزنهای جداسازی است. در همان زمان، کمترین احتمال شناسایی درست کلاسیفایر  $\text{آم}$  با  $P_i$  معلوم می شود ، پایین ترین احتمال شناسایی درست تمام کلاسیفایرها متشکل از بردار  $P = (P_1, P_2, \dots, P_m)$  است.

در اینجا فرض بر اینست که بردارهای ویژگی و کلاسیفایر تک ، طراحی شده اند. در اصل چگونگی ترکیب و ساخت یک تصمیم بر طبق بردار خروجی  $y_i$  هر کلاسیفایر را در نظر می گیریم. در ابتدا، نوعی دنباله از کلاسیفایر تک برای نوع هدف را بر طبق بردار خروجی  $y_i$  هر کلاسیفایر ایجاد می-

کنیم یعنی نوعی دنباله گذاری تصمیم‌گیر برای طرح است. بنابراین دنباله گذاری همسان  $M$  کلاسیفایر را محاسبه می‌کنیم و نوع هدف را توسط دنباله گذاری همسان تعیین می‌کنیم.

برای مثال بهترین رتبه گذاری نوع هدف، نوع هدفی است که سیستم شناسایی می‌کند و انتخاب وزن هر کلاسیفایر هنگام محاسبه دنباله گذاری همسان اهمیت بسیار دارد. بردار وزن دهی  $W = (W_1, W_2, \dots, W_m)$  بر طبق پایین ترین بردار احتمال تشخیص درست محاسبه می‌شود. اینکه چرا آن را توسط احتمال تشخیص درست کلی محاسبه می‌کنیم، به خاطر اینست که اساساً برای اینکه نمونه‌های هر هدف متفاوت است و نمونه‌های برخی اهداف بیشتر از بقیه است، در این صورت حتی نرخ شناسایی با نمونه‌های کم خیلی پایین است، همچنان احتمال تشخیص درست کلی می‌تواند بالا باشد، داشتن احتمال کلاس بندی یکسان برای کلاس‌فایرها درست نیست. بنابراین بردار وزدهی  $W$  را از بردار احتمال شناسایی درست  $p$  بدست می‌آوریم. و مزیت دیگری که وجود دارد، حتی احتمال شناسایی تعدادی کلاسیفایر برای هدف پایین است، همچنان کلاس بندی قدرتمندی است.



شکل ۳-۱۵- مدل ترکیبی چند کلاسیفایر [۲۴]

### ۳-۶-۲-۲- الگوریتم ترکیبی کلاسیفایر های چند گانه

روشهای گوناگونی برای حل مسئله دنباله گذاری همسان وجوددارد [۲۵] ، درجه وابستگی یا غیر وابستگی دنباله گذاری با وزن دهی تابع فاصله Minkowski سنجیده می شود. الگوریتم به قرار زیر است:

مرحله ۱: بردار دنباله  $R_i = (r_i^1, r_i^2, \dots, r_i^j, r_i^N)$  هر کلاسیفایر را محاسبه می کنیم، که  $r_i^j$  از میان  $y_i = (y_i^1, y_i^2, \dots, y_i^j, y_i^N)$  و بدون تکرار بر طبق دامنه  $y_i^j$  متعلق به بردار خروجی که  $(y_i^1, y_i^2, \dots, y_i^j, y_i^N)$  است کلاسیفایر  $i$  ام که  $i=1,2,\dots,N$  و  $j=1,2,\dots,M$  است

مرحله ۲: محاسبه ضرایب وزدهی  $w_i$  کلاسیفایر  $i$  (تصمیم گیری) با پایین ترین بردار احتمال شناسایی  $P$  بر طبق معادله (۱) :

$$w_i = \frac{P_i}{\sum_{k=1}^M P_k} \quad (i = 1, 2, \dots, M) \quad (19-3)$$

مرحله ۳: هنگامی که گروه تصمیم گیری چند - کلاسیفایر هدف  $j$  را در عدد  $t$  دسته بندی می کند، طبق معادله ۲۰-۳، فاصله Minkowski میان دنباله گروه کلاسیفایر با دنباله هر کلاسیفایر به هدف  $j$  محاسبه می شود.

$$d_{jt} = \left[ \sum_{i=1}^M |w_i(r_i^j - t)|^q \right]^{\frac{1}{q}} \quad (j = 1, 2, \dots, N \quad t = 1, 2, \dots, N) \quad (20-3)$$

$T$  مقدار دنباله همسان که متعلق به  $N$  ...  $1, 2$  و بدون تکرار است.  $q$  پارامتر فاصله است. هنگامی که  $q=2$  قدر مطلق میانگین است، که به اسم وزن دهی فاصله hamming است. هنگامی که  $q=1$  وزن دهی فاصله اقلیدسی است. برای مثال ۸ کلاسیفایر برای دسته بندی هدف  $j$  وجود دارد و ۴ کلاسیفایر هدف  $j$  را در عدد ۱ دسته بندی میکنند، ۲ کلاسیفایر در عدد ۲ و ۲ کلاسیفایر در عدد ۳

دسته بندی می‌کنند اگر  $w_i = 1$  و  $q=1$  داریم سپس :

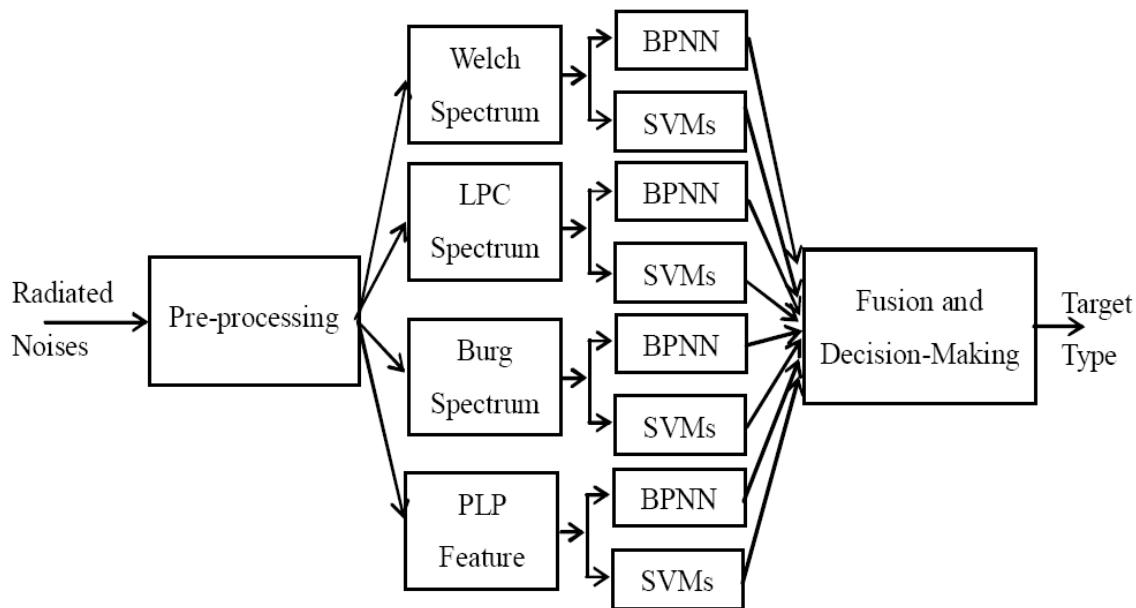
$$d_{11} = 4x|1 - 1| + 2 \times |2 - 1| + 2|3 - 1| = 6$$

مرحله ۴: در این لحظه مسئله دنباله گذاری همسان به حل مسئله تخصیص تبدیل می‌شود به صورت معادله ۳:

$$\min\{d = \sum_{j=1}^N \sum_{t=1}^N d_{jt} z_{jt}\} = \dots$$

$$\dots = \min \left\{ d = \sum_{j=1}^N \sum_{t=1}^N \left[ \sum_{i=1}^M |w_i(r_i^j - t)|^q \right]^{\frac{1}{q}} z_{jt} \right\} \quad (21-3)$$

که  $z_{jt}$  متغیر تصمیم گیری است،  $1 = z_{jt}$  نشان می‌دهد که گروه تصمیم گیری چند کلاسیفایر هدف  $j$  را در عدد  $t$  دسته بندی کرده است،  $0 = z_{jt}$  نشان می‌دهد که آنها در عدد  $t$  دسته بندی نکرده اند. پس ما ترتیب گذاری همسان گروه چندین کلاسیفایر را بدست می‌آوریم یعنی ترتیب گذاری که برای شناسایی هدف پس از تصمیم گیری مرکب چند-کلاسیفایر می‌تواند استفاده شود بنابراین بهترین نوع هدف، نوع هدف نهایی ما به نام نتیجه شناسایی است. بردارهای ویژگی شامل [۲۶] Welch و [۲۷] SVM و [۲۸] PLP و طیف Burg، طیف LPC و کلاسیفایرها شامل .



شکل ۱۶.۳. سیستم ترکیبی مورد استفاده [۲۴]

### ۳-۷-۳- استخراج ویژگی مرکب طیف خطی جداسازی شده نویز کشتی توسط بسته موجک<sup>۱</sup>

۱-۷-۳ - مقدمه

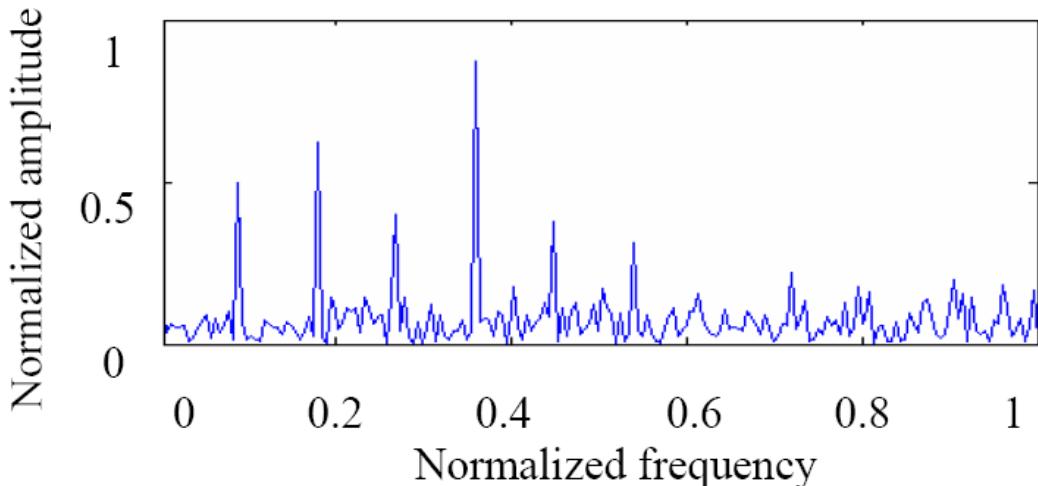
ویژگی طیف خطی مدوله شده یک مجموعه از اجزاء طیف خطی گسسته است که در محور فرکانسی پروانه قرار گرفته اند و فرکانس های هارمونیک آن در شکل ۱۷-۳ معلوم است . در شکل ۱۷-۳ طیف خطی اول ، ویژگی محور فرکانسی پروانه و دامنه های هارمونیک های آن ویژگی دامنه است . بردار ویژگی دامنه ، طیف خط اول به صورت زیر بیان می شود:

$$A = [A(1) \ A(2) \ A(3) \ \dots \ A(D)]^T \quad (۲۲-۳)$$

<sup>۱</sup>Wavelet Packet (WP)

ویژگی محور فرکانسی پروانه به صورت F بیان می گردد.

آنالیز بسته موجک یک روش عالی جهت آنالیز سیگنال است. آنالیز بسته موجک تعمیم تجزیه موجک است که آنالیز قوی‌تر سیگنال را پیشنهاد می‌کند و دارای مزایای بیشتری است. این روش دارای مراحل زیر است [۲۹].



شکل ۱۷.۳. طیف دمدوله شده یک کشتی بازرگانی [۲۹]

### ۲-۷-۳- تبدیل بسته موجک

بسته‌های موجک با تعمیم ارتباط میان تخمین‌های چند-تجزیه‌ای و موجک‌ها توسط *Gifman*، *Wickerhauser* و *Meyer* مطرح شد.

$$\Psi_{j+1}^{2p}(t) = \sum_{h=-\infty}^{+\infty} h(n) \Psi_j^P(t - 2_n^j) \quad (23-3)$$

$$\Psi_{j+1}^{2p+1}(t) = \sum_{h=-\infty}^{+\infty} g(n) \Psi_j^P(t - 2_n^j) \quad (24-3)$$

با  $N \in j \in [0, 2^{j-1}]$  و  $p \in [0, 2^{j-1}]$  ،  $g(*)$  و  $h(*)$  جفت توام فیلترهای آینه‌ای  $\Psi$  تایی<sup>۴</sup> می‌باشند. در

مقیاس اول، توابع  $\Psi_0$  و  $\Psi_1$  با موجک‌های پدر و مادر  $\phi(t)$  و  $\psi(t)$  با ویژگیهای کلاسیک زیر می‌توانند معین شده باشند.

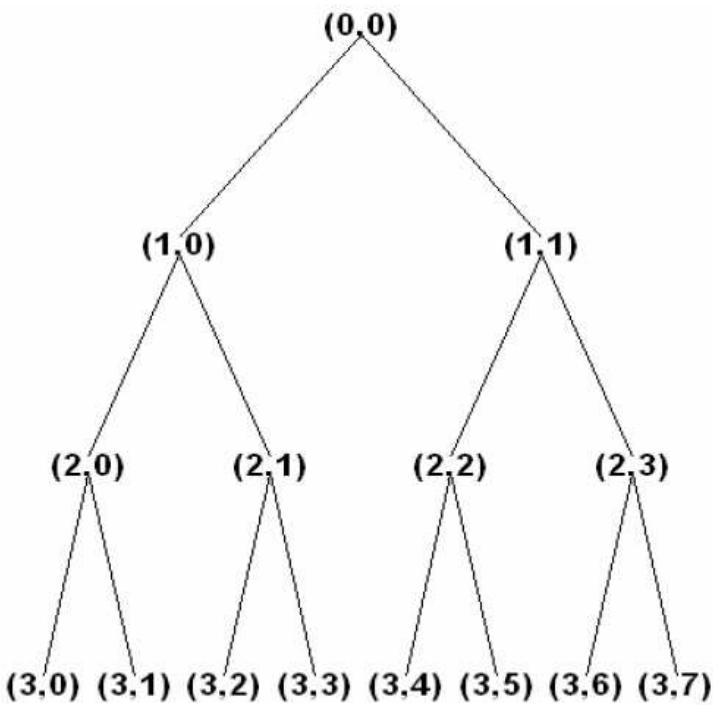
مجموعه توابع انتقال، انبساط و نرمال‌سازی  $\Psi_j^{p,n} = 2^{-\frac{j}{2}} \Psi_p(2_t^{-j} - h)$ ، فیلترهای  $\Psi$  تایی<sup>۴</sup> و  $g(*)$ ، مرتبط با بسته‌های موجک را می‌سازند.  $N \in j \in [0, 2^{j-1}]$  مشخصه مقیاس است، می‌تواند با مشخصه فرکانسی مشخص شده باشد و  $K$  مشخصه مکان است. ثابت می‌شود که اگر  $\{\Psi_j^{p,n}\}_{n \in \mathbb{Z}}$  یک پایه عمود برهم از فضای  $V_j$  باشد سپس دسته  $\{V_{j+1}^{2p+1,n}\}_{n \in \mathbb{Z}}$  نیز یک مبنا عمود برهم از  $V_j$  می‌باشند.

تقسیم‌بندی دوتایی بازگشتی از فضاهای برداری در درخت باینری  $T$  نشان داده می‌شود. برای مثال شکل ۱۸-۳ یک درخت باینری با عمق ۳ را نشان می‌دهد. برای هر گره  $(j, p) \in N$  با  $j \in [0, 2^{j-1}]$  یک فضای  $V_j^P$  را با پایه عمود بر هم  $\{\Psi_j^P(t - 2_n^j)\}_{n \in \mathbb{Z}}$  مرتبط می‌کنیم. بطوریکه  $V_j^P = V_{j+1}^{2P} \oplus V_{j+1}^{2P+1}$ . روابط تقسیم‌بندی، دو پایه عمود برهم ایجاد می‌کند، آشکار است که

نمایش بسته موجک کامل است. یعنی چندین زیر مجموعه از بسته‌های موجک وجود دارد که پایه‌های عمود بر هم را برای فضای اصلی  $V_0$  ایجاد می‌کنند. هنگامی که آنها یک کتابخانه بزرگ تشکیل می‌دهند. این پایه‌ها می‌توانند به آسانی در یک درخت باینری سازمان‌دهی شده باشند و به طور موثری برای نقاط حدی توابع، هزینه مخصوص را جستجو کنند.

---

<sup>۴</sup>quadrature mirror filters



شکل ۳-۱۸- یک درخت باینری با عمق ۳ [۲۹]

در ادامه ، مجموعه  $B = \{\Psi_j^{p,n}\}_{(j,p) \in T}$  پایه‌ای از  $L^2(R)$  و درخت  $T$  که مجموعه گره‌های  $(j,p)$ ، برگهای آن می‌باشد را فرمی خوانیم .

با یک پایه  $B$  و درخت  $T$  مرتبط با آن ، امکان تجزیه هر تابع  $x$  از  $L^2(R)$  در  $B$  وجود دارد . در هر گره  $(j,p) \in T$  ضرایب بسته موجک ،  $W_j^{P(n)}$  از  $V_j^P$  در زیر فضای  $n$  در مکان  $X$  توسط ضرب داخلی معین می‌شود :

$$W_j^P(n) = \int W_j^P(t - 2^j n) x(t) dt \quad (25-3)$$

برای سیگнал گسسته با نمونه‌هایی با فاصله  $N$  ، تبدیل بسته موجک گسسته با الگوریتم بانک فیلتر سریع محاسبه می‌شود که نیاز به  $O(N \log N)$  عملیات دارد .

### ۳-۷-۳- استخراج ویژگی مرکب طیف خطی دمدوله شده براساس بسته موجک

در باندهای فرکانسی مختلف ، طیفهای دمدوله شده نویز کشتی به طور واضح متفاوت است [۳۱، ۳۲] . ویژگیهای طیف دمدوله شده از برخی باندهای باریک ، نرخ سیگنال به نویز و قابلیت شناسایی بهتری دارند. بعلاوه بسته موجک یک روش آنالیز سیگنالی عالی است . بنابراین ، دنبال روش استخراج ویژگی مرکب طیف خطی دمدوله شده نویز کشتی با بسته موجک در این بخش هستیم .

### ۱-۳-۷-۳ تجزیه سیگنال نویز کشتی توسط بسته موجک

سیگنال نویز کشتی توسط بسته موجک تجزیه می شود . روش تجزیه سیگنال در شکل ۳ معلوم می شود . سری زمانی سیگنال نویز کشتی به این صورت مشخص می شود :

$$\{x(k) | k \in [1, VK]\} \quad (26-3)$$

#### ۱) انتخاب سیگنال

سیگنال نویز کشتی ناپایدار و سیگنال به نویز آن نیز متغیر با زمان است. یک قسمت داده از سیگنال نویز کشتی با طول  $V/1$  سیگنال اصلی که سیگنال به نویز آن باید بیشتر باشد ، انتخاب می کنیم . فرآیند انتخاب سیگنال یک فرآیند متقابل انسان- ماشین است.

بخش انتخابی سیگنال به صورت زیر مشخص می شود:

$$\{x'(k) | k \in [1, K]\} \quad (27-3)$$

#### ۲) تجزیه بسته موجک سیگنال

بعد از آنکه سری زمانی  $\{x'(k) | k \in [1, K]\}$  توسط بسته موجک به  $\hat{J}$  دسته تجزیه می شود ، ضرایب بسته موجک زیر فضاهای مختلف را بدست می آوریم :

$$\left\{ S_k^{j,n} \middle| n \in [1, 2^j - 1], k \in \left[1, \frac{k}{2^j}\right] \right\} \quad (28-3)$$

(j, n) مشخص کننده زیر فضای (j, n) از j طبقه تجزیه بسته موجک را مشخص می‌کند، که گره‌های (j, n) درخت باینری با عمق j نامیده می‌شود. زیرنویس k مقدار ضرایب بسته موجک از زیرفضای (j, n) را مشخص می‌کند.

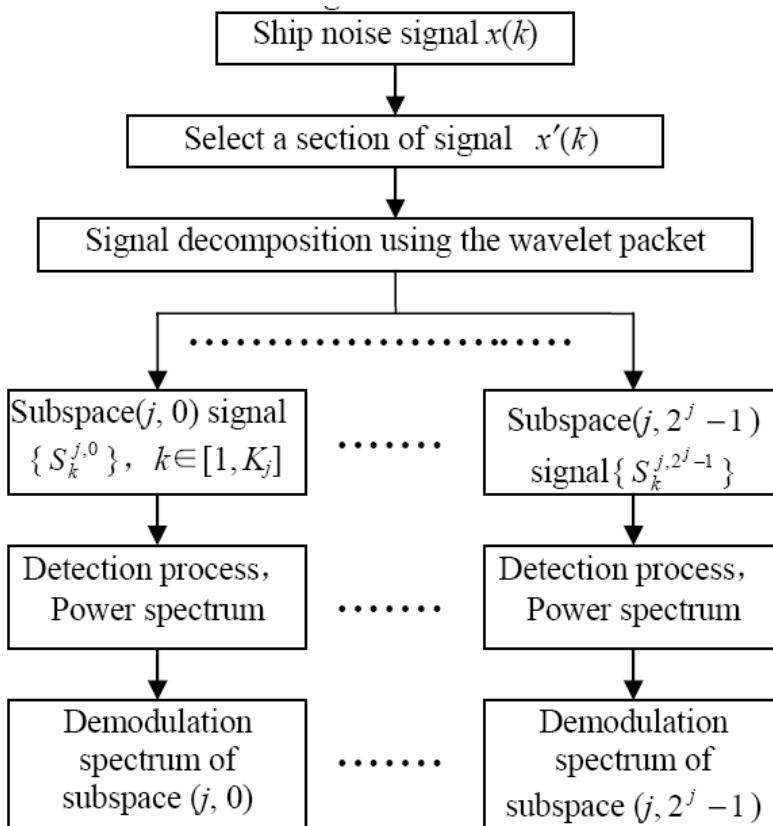
### ۲-۳-۷-۳- طیف جداسازی شده چندین زیرفضا مبتنی بر بسته موجک

شکل ۱۹-۳ فلوچارت طیف دمدوله شده چندین - زیرفضای نویز کشتی مبتنی بر بسته موجک را نشان می‌دهد. فرآیند تشخیص ضرایب بسته موجک  $\{S_k^{j,n}\}$  به صورت  $\{(S_k^{j,n})^2\}$  بیان می‌شود و یکسوکنندگی مربعی نامیده می‌شود. طیف دمدوله شده از زیر فضای (j, n) چگالی طیف توان ضرایب بسته موجک  $\{S_k^{j,n}\}$  به صورت زیر بیان می‌شود:

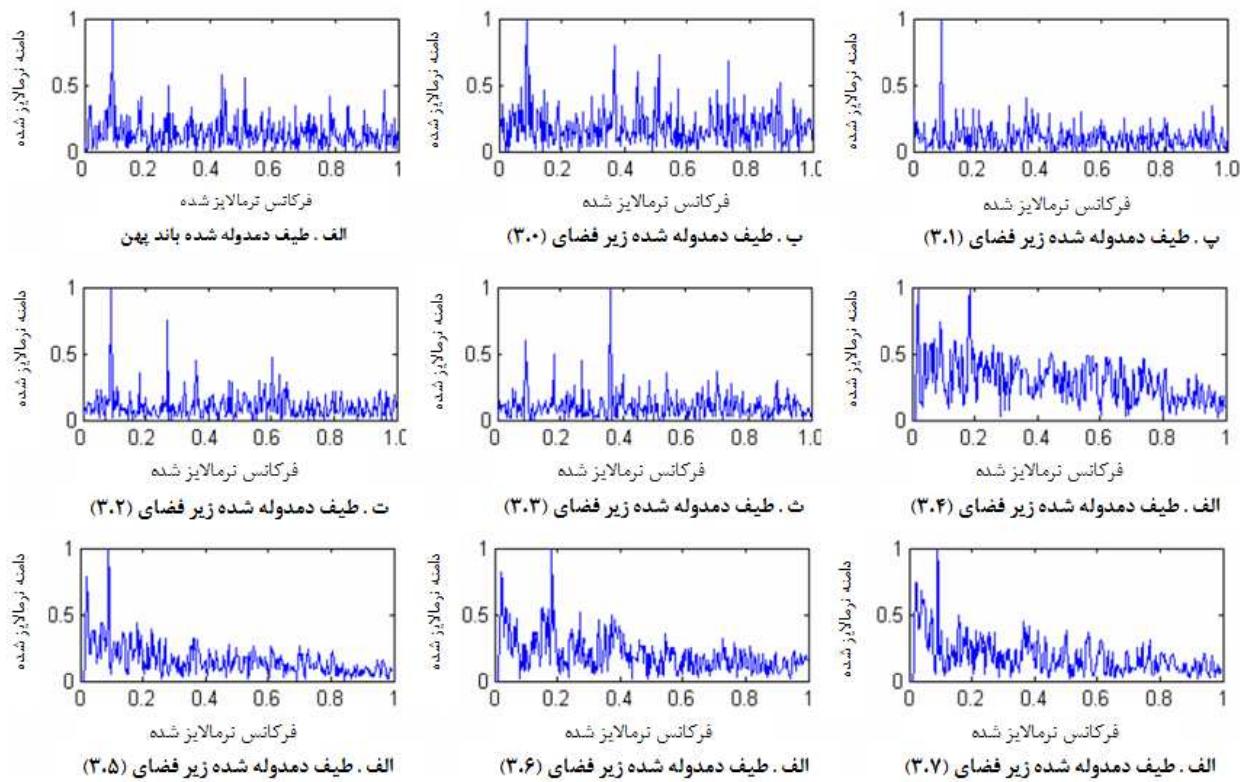
$$Z_l^{j,n} = \frac{1}{K_j} \left| \text{FFT}(\left(S_k^{j,2^j-1}\right)^2) \right| \quad (29-3)$$

که  $K_j = \frac{K}{2^j}$  است،  $l \in [1, K_j/2]$

شکل ۲۰-۳ نویز کشتی شامل چندین- زیر فضای ویژه را نشان می‌دهد. شکل ۲۰-۳-(الف) طیف دمدوله شده باند پهن از یک هدف معین با پروانه ۴ تیغه را نشان می‌دهد. از آنجاییکه تنها طیف خطی اول (طیف خط محور فرکانسی) بدست آمده می‌تواند باشد پس تعداد تیغه‌ها تشخیص داده نمی‌شود شکل ۲۰-۳-(ب) الی ۲۰-۳-(خ) طیف دمدوله شده زیر فضای (۰, ۳, ۰) الی (۳, ۷) را نشان می‌دهد. با توجه شکل ۳.۲۰، طیف خط دمدوله شده از زیر فضای (۳, ۲) و (۳, ۳) نرخ سیگنال به نویز بیشتری نسبت به دیگر زیر فضاهای دارند و به عنوان یک هدف با پروانه ۴ تیغه‌ای می‌تواند شناسایی شده باشد و تعداد تیغه توسط طیف خطی دمدوله شده را زیر فضاهای (۰, ۳)، (۱, ۳)، (۴, ۳)، ... (۷, ۳) نمی‌تواند شناسایی شده باشد زیرا نرخ‌های سیگنال به نویز این زیر فضاهای خیلی پایین است.



شکل ۳-۱۹-۳- فلوچارت طیف دمدوله شده چندین - زیرفضای نویز کشتی مبتنی بر بسته موجک [۲۹]



شکل ۳-۲۰-۳- طیف دمدوله شده زیر فضای چندگانه نویز کشتی مبتنی بر بسته موجک طبقه-۳- [۲۹]

بنابراین ، تاثیر شناسایی با طیف خطی دمدوله شده زیر فضاهای مختلف ، متفاوت است ، اما برخی زیرفضاهای تاثیر بهتری نسبت به دیگر زیر فضاهای دارند و ویژگی مرکب طیف خطی دمدوله شده نویز کشتی را از این زیر فضاهای بهتر بدست می‌آید . برای مثال ، ویژگی مرکب طیف خط دمدوله شده از زیر فضای  $(3,2)$  و  $(3,3)$  بهترین می‌باشد که در شکل ۶ نمایش داده می‌شود .

### ۳-۳-۷-۳- روش ارزیابی داده بر اساس آنتروپی اطلاعات

فرض کنید فضای احتمالاتی منبع اطلاعات گسسته  $X$  باشد :  

$$\begin{bmatrix} x \\ p \end{bmatrix} = \begin{bmatrix} a_1, a_2, \dots, a_q \\ p_1, p_2, \dots, p_q \end{bmatrix}$$
 با  $p_i \geq 0$  و  $\sum_{i=1}^q p_i = 1$  ، آنگاه آنتروپی اطلاعات منبع  $X$  به صورت زیر تعریف می‌شود :

$$H(X) = -E(\log p_i) = -\sum_{i=1}^q p_i \log_2 p_i \quad (30-3)$$

آنtronپی اطلاعات وزن دار به صورت معادله ۳۱-۳ تعریف می‌شود :

$$H_w(X) = -\sum_{i=1}^q w_i p_i \log_2 p_i \quad (31-3)$$

$w_i$  وزن رخداد  $a_i$  و  $w_i \geq 0$  [۳۲] . در این الگوریتم پیشنهادی میزان آشفتگی داده‌ها تخمین زده می‌شود .

### ۴-۳-۷-۳- معیار بررسی طیف دمدوله شده زیر فضای چند تایی با استفاده از اطلاعات آنتروپی

نتایج تحقیقات نشان می‌دهد : اطلاعات شناسایی شامل طیف دمدوله شده دارای رابطه با چگالی طیف ، اندازه عددی طیف خط والی آخر است . بنابراین درجه آشفتگی طیف دمدوله شده نویز کشتی را توسط آنتروپی اطلاعات تخمین زده می‌شود .

نرمال سازی جمع طیف دمدوله شده  $\left\{ Z_L^{j,n} \mid l \in \left[1, \frac{k_j}{2}\right] \right\}$  به صورت زیر تعریف می‌شود :

$$Z_l^{j,n} = \frac{Z_l^{j,n}}{\sum_{l=1}^{K_j/2} Z_l^{j,n}} \quad (32-3)$$

که  $K_j = K/2^j$ ,  $l \in [1, K_j/2]$  می‌باشند.

بعد از نرمال سازی جمع مجموعه طیف دمدوله شده  $\{Z_l^{j,n} | l \in [1, K_j/2]\}$  در معادله

$Z_l^{j,n} \geq 0$  صدق می‌کند و  $\sum_{l=1}^{K_j/2} Z_l^{j,n} = 1$

با آنتروپی اطلاعات تخمین بزنیم.

انتروپی اطلاعات وزن‌دار طیف دمدوله شده  $\{Z_l^{j,n} | l \in [1, K_j/2]\}$  به صورت زیر بیان می‌شود:

$$P^{j,n} = H_w(Z_l^{j,n}) \quad (33-3)$$

که  $\{w(k) | k \in [1, K]\}$  ضرایب وزن هستند. درجه آشفتگی طیف دمدوله شده زیر فضای  $(j, n)$  است

که نرخ سیگنال به نویز طیف دمدوله شده زیر فضای  $(j, n)$  به یک فضای ویژه را بیان می‌کند [۳۰].

تحت شرایط کلی، با  $P^{j,n}$  کوچکتر، نرخ آشفتگی زیر فضای  $(j, n)$  کمتر است. در زیر فضای

کوچکتر، اطلاعات شناسایی بیشتری وجود دارد. بنابراین برخی زیر فضاهای را بر طبق  $P^{j,n}$  انتخاب

می‌کنیم.

ویژگی مشخصه زیر فضاهایی که اطلاعات شناسایی بیشتری دارند از رابطه زیر بدست می‌آید:

$$U = \left[ u(p^{j,0} - P^{j,0}), \dots, u(p^{j,n} - P^{j,n}), \dots, u(p^{j,2^j-1} - P^{j,2^j-1}) \right] \quad (34-3)$$

$u(t) = 0$  و گرنه  $u(t) = 1$  آنگاه  $t \geq 0$  است. اگر  $u(t)$  تابع پله است.

$P^{j,n}$  معیار درجه آشفتگی زیر فضای  $(j, n)$  را مشخص می‌کند. اگر  $p^{j,n} \geq P^{j,n}$ .

اطلاعات شناسایی بیشتری را شامل می‌شود.

### ۳-۷-۵- استخراج ویژگی مرکب طیف خطی دموله شده نویز کشتی

از معادله (۳۴-۳) مشاهده می‌شود که المان  $U(n)$  در  $U$  یک یا صفر است. اگر  $1 = U(n)$  نشان می‌دهد که زیر فضای  $(j, n)$  شامل اطلاعات بیشتری است. بنابراین ویژگی مرکب زیر فضا با  $U(n) = 1$  را استخراج می‌کنیم.

با استفاده از الگوریتم بازسازی بسته موجک [۶]، سیگنال را با استفاده از زیر فضایی که  $1 = U(n)$  بازسازی می‌کنیم. سیگنال بازسازی شده به صورت  $\{y(k)|k \in [1, K]\}$  بیان می‌شود.

شکل ۲۱-۳ فرآیند استخراج ویژگی مرکب طیف خط دموله شده نویز کشتی را نشان می‌دهد. بعد از فرآیند تشخیص، پایین گذر و نمونه برداری سیگنال بازسازی شده  $y(k)$  سری زمانی  $y'(k)$  را بدست می‌آوریم:

$$\{(y'(k)|k \in [1, K']\} \quad (35-3)$$

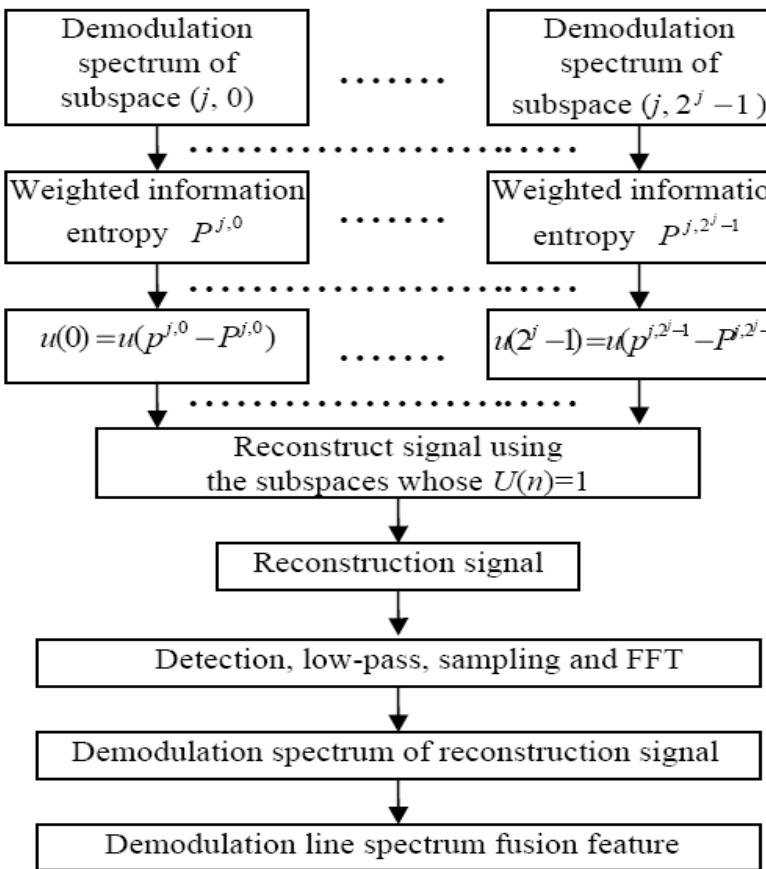
طیف دموله شده سیگنال بازسازی، چگال طیف توان  $y'(k)$  است که به صورت:

$$Z(l) = \frac{1}{K'} |FFT(y'(k)^2)| \quad l \in [1, K'/2] \quad (36-3)$$

بیان می‌شود. طیف‌های خطی را از طیف دموله شده  $\{Z(l)|l \in [1, K'/2]\}$  سیگنال بازسازی استخراج می‌کنیم. فرکانس طیف خط اول محور- فرکانسی پروانه اهداف است که با  $F$  مشخص می‌شود. بردار ویژگی دامنه  $D$  طیف خطا اول به صورت:

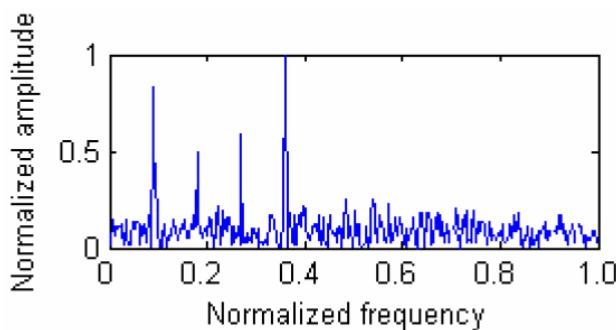
$$A^J = [A^J(1) \ A^J(2) \ \dots \ A^J(D)]^T \quad (37-3)$$

تعریف می‌شود. ویژگی مرکب طیف خطی دموله شده مبتنی بر بسته موجک توسط  $A^J$  و  $F$  ساخته می‌شود.



شکل ۳-۲۱-۳- استخراج ویژگی مرکب طیف خطی دمدوله شده نویز کشته [۲۹]

طیف دمدوله شده در شکل ۲۲-۳ از زیر فضای (۲ و ۳) و زیر فضای (۳، ۳) در شکل ۲۰-۳ بدست می- آید . با مقایسه شکل ۲۲-۳ و ۲۰-۳ ملاحظه می شود که طیف خطی دمدوله شده از سیگنال بازسازی ، سیگنال به نویز بیشتری و قابلیت شناسایی بهتری نسبت به هر زیر فضا در شکل ۲۰-۳ دارد .



شکل ۳-۲۲-۳- طیف دمدوله شده سیگنال بازسازی شده [۲۹]

### ۳-۸-۳- کاربرد سیستم هوشمند در شناسایی نویز انتشاری از هدف زیر آب

#### ۱-۸-۳- مقدمه

این روش یک سری ویژگی‌های طیف حاصل از تبدیل فوریه سیگنال ورودی را استخراج و با استفاده از یک تابع فاصله تصمیم‌گیری می‌نماید. مراحل آن به شرح زیر است [۱۰].

#### ۲-۸-۳- آنالیز مشخصات نویز زیر آب

استخراج ویژگی نویز زیر آب یک نکته کلیدی در تعیین هدف است که باید برخی ملزومات را برآورد کند [۳۴] مانند :

(الف)- مقدار مشخصات سیگنال باید نتایج متوسط آماری باشد.

(ب)- در همان شرایط (همان کشتی، هان سرعت) احتمال تکرار مشخصات نزدیک به یک باشد.

(پ)- اشتراک کلاسهای سیگنال متفاوت در حد امکان باید کوچک باشد.

(ت)- الگوریتم استخراج ویژگی باید ساده و آسان پیاده شود.

براساس تعداد زیادی آنالیز داده، این شش پارامتر را بعنوان ویژگی‌های سیگنال در نظر گرفتیم.

• تعداد  $N_{ls}$  طیف خطی

• طول متوسط  $A_{ls}$  از طیف خطی مجاور

• مکان  $P_l$  طیف خطی که ماکزیمم سطح توان را دارد.

• سطح متوسط  $L$  طیف خطی بر روی طیف توان متوسط

- موقعیت  $B_m$  باند طیف ماکزیمم

- شیب  $S_b$  طیف از باند طیف ماکزیمم

برخی تعریف‌ها را قبل از بیان استخراج ویژگی نشان می‌دهیم. برای مثال چه نوع طیفی به عنوان خط طیفی در نظر گرفته می‌شود؟ چگونه مکان دقیق خط طیفی را محاسبه کنیم؟ ماکزیمم باند طیف چیست؟ و الی آخر. مشهود است که برخی روش‌ها مبهم هستند. آنالیز فازی یک انتخاب درست برای این نوع مسائل است.

یک سری از عبارتهای ریاضی در بخش بعدی برای روش‌ها معین خواهد شد.

### ۳-۸-۳ الگوریتم تصمیم گیری

قبل از استخراج ویژگی با داده‌های اصلی در حوزه فرکانس سروکار داریم. ۴ تا ۳۲ بار متوسط تبدیل فوریه سریع ۱۰۲۴ نقطه‌ای برای جداسازی قسمتهای جدا از داده زمانی گرفته می‌شود. فرکانس نمونه برداری حدود ۵ برابر فرکانس قطع سیگنال ورودی است. بر طبق آنالیز فازی، یک الگوریتم پیش هموارسازی برای حذف نویز و هموارسازی بیشتر طیف توان کلی به کار برده می‌شود. در این روش بردار مشخصه به صورت بیانگر درست آن کلاس استخراج می‌شود.

تقسیم بندی داده ورودی در  $M$  قسمت که هر قسمت دارای  $N$  نقطه است :

$$x_m(0), \dots, x_m(N-1) \quad m = 1, \dots, M \quad (38-3)$$

فرض کنید  $DFT$ ، بخش  $m$  برابر است با :

$$X_m(l) = \sum_{k=0}^{N-1} x_m(k) \exp(-2\pi j k l / N) \quad (39-3)$$

برای طیف متوسط سیگنال ورودی داریم :

$$X(l) = \frac{1}{M} \sum_{m=1}^M |X_m(l)| \quad (40-3)$$

طیف متوسط کل تعریف می شود :

$$A = \frac{2}{N} \sum_{l=0}^{\frac{N}{2}-1} X(l) \quad (41-3)$$

مقدار طیف خطی  $l$  است که  $X(l) \geq A + B_1$  و  $B_1$  پارامتر همسایگی است .

مجموعه طیف خطی به صورت رابطه ۵ است :

$$V = \{X(l) : X(l) \geq A + B_1\} \quad (42-3)$$

با مرتب سازی مقدار  $X(l)$  در مجموعه  $V$  بر طبق دامنه از بزرگ به کوچک به صورت  $v_1, \dots, v_P$  که

$$v_i = X(l_i) \text{ و } v_i \in V$$

$$P1 = l_1, N_{ls} = p, A_{ls} = \frac{l_p - l_1}{p - l} \quad (43-3)$$

با انتخاب پارامتر  $B_2$  و ایجاد متوسط محلی  $A_i$  در همسایگی  $i$  این طیف خطی داریم :

$$A_i = \frac{1}{2B_2} \sum_{k=1}^{B_2} [X(l_i - k) + X(l_i + k)] \quad (44-3)$$

توان طیف خطی  $i$  ام به صورت  $Q_i = X(l_i) - A_i = v_i - A_i$  تعریف می شود. یعنی

$$L = \frac{1}{P} \sum_{i=1}^P Q_i \quad (45-3)$$

قرار می دهیم :

$$C_l = \frac{1}{B_3} \left\{ X(l) + \sum_{k=1}^{B_3} [X(l - k) + X(l + k)] \right\} \quad (46-3)$$

$$\cdot C_{l_0} = \max \left\{ C_l : l = 0, \dots, \frac{N}{2} - 1 \right\} \text{ اگر}$$

داریم :

$$B_m = l_o, S_b = \frac{1}{B_4} [C_{lo} - C_{lO} + B_4] \quad (47-3)$$

که پارامترهای  $B_2$  ،  $B_3$  و  $B_4$  می توانند در الگوریتم اصلاح شوند .

شش پارامتر از داده های هموار شده استنتاج می شود . یک متريک برای اندازه گيری فاصله ميان هر دو بردار ايجاد می شود . فرض کنيد يك کلاس جديد با يك بردار ويژگي زير داريم :

$$C = (N_{ls}, A_{ls}, P_1, L, B_m, S_b) \quad (48-3)$$

بردار ويژگي برخی کلاسهای استاندارد به صورت زير است :

$$C_0 = (N_{ls0}, A_{ls0}, P_{10}, l_0, B_{m0}, S_{b0}) \quad (49-3)$$

فاصله ميان  $C$  و  $C_0$  به صورت زير تعریف می شود :

$$D(C, C_0) = [w_n |N_{ls} - N_{ls0}|^2 + w_a |A_{ls} - A_{ls0}|^2 + \dots + w_s |S_b - S_{b0}|^2]^{1/2} \quad (50-3)$$

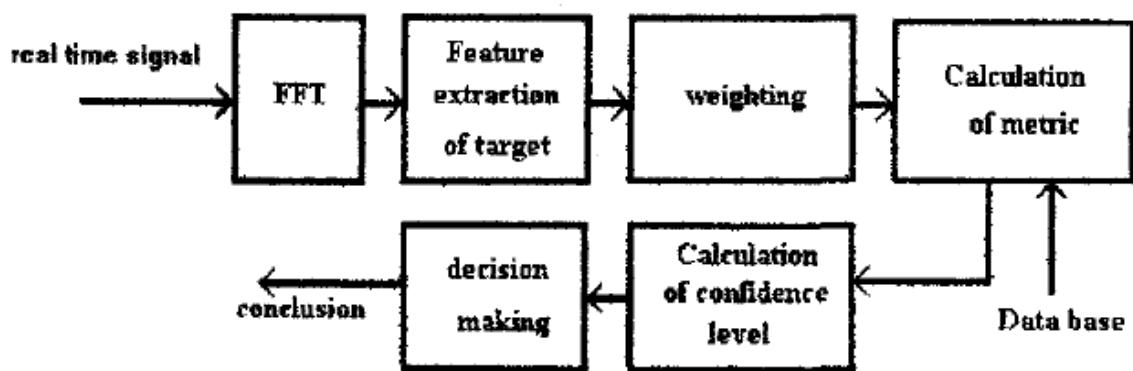
... يك مجموعه از مقادير منفي هستند که در فرایند تصمیم گیری تنظیم می شوند .  $w_a, w_n$

مقدار درجه اطمینان تصمیم گیری با عکس  $D(C, C_0)$  نسبت دارد . روش تصمیم گیری در شکل ۳-۳ نشان داده می شود .

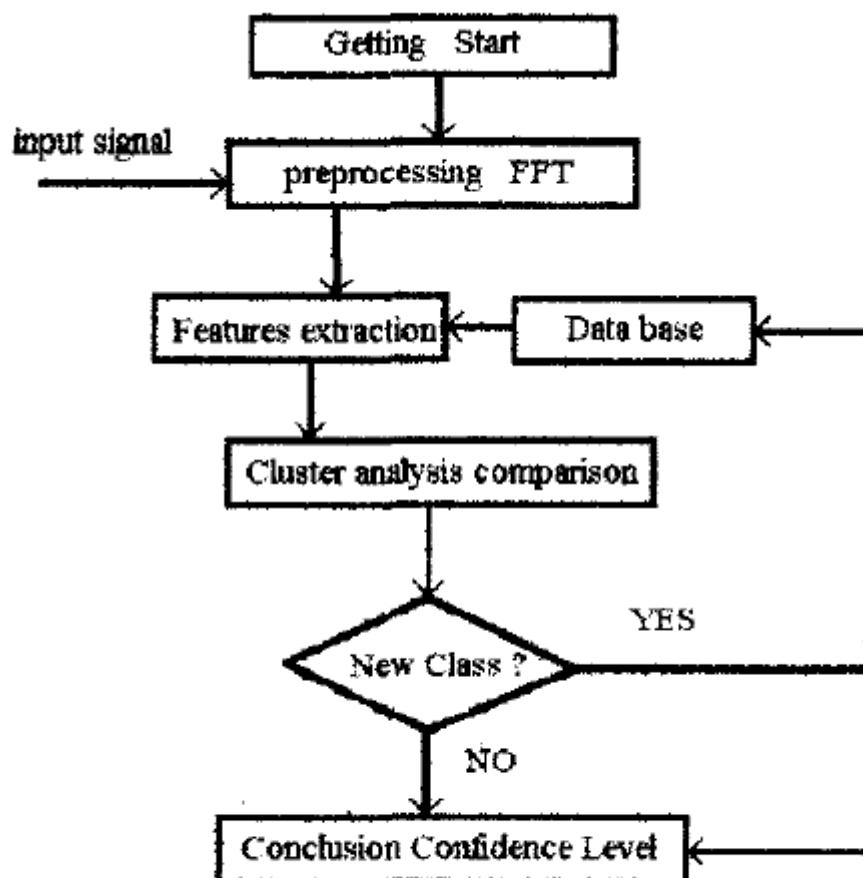
داده زمان واقعی برای انجام پیش پردازش وارد می شود . بنابراین سیگنال خروجی دیجیتال برای بدست آوردن اطلاعات حوزه فرکانس پردازش می شود .

الگوریتم آنالیز فازی برای استخراج بردار ويژگی سیگنال ورودی به کار می رود . روش تطبیق بردار اصلی برای محاسبه فاصله ميان این سیگنال و هر نمونه از پایگاه داده استفاده می شود . مقدار آستانه

از پیش انتخابی با فاصله و مقدار مینیمم مقایسه می شود ، در صورت وجود ، پیدا می شود . سرانجام ، تصمیم گرفته می شود بلوک دیاگرام سیستم کاوش در شکل ۲۴-۳ نشان داده می شود .



شکل ۲۴.۳. روش آنالیز خوشای برای تشخیص هدف [۱۰]



شکل ۲۴.۳. بلوک دیاگرام سیستم خبره کاوش [۱۰]

# فصل چهارم

الگوريتم پيشنهادي

## ۱.۴ مقدمه

در این فصل ابتدا الگوریتم پیشنهادی معرفی می‌گردد و سپس مراحل مختلف آن توصیف می‌شود . با توجه به اینکه جهت کلاس‌بندی از شبکه عصبی در این پایان‌نامه استفاده می‌گردد ، در انتهای این فصل شبکه عصبی به کار گرفته شده مختصرأً توضیح داده می‌شود .

## ۲.۴ الگوریتم پیشنهادی

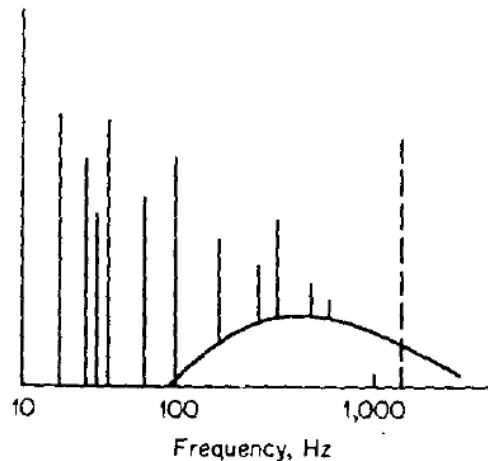


بلوک دیاگرام الگوریتم پیشنهادی در شکل ۱-۴ نشان داده شده است . همانطور که از شکل ۱-۴ قابل مشاهده است الگوریتم پیشنهاد شده از ۶ مرحله تشکیل یافته است . مراحل الگوریتم پیشنهادی به ترتیب عبارتند از مرحله اول تغییر نرخ نمونه برداری ، مرحله دوم نرمال سازی ، مرحله سوم محاسبه طیف سیگنال ، مرحله چهارم محاسبه ماتریس H ، مرحله پنجم استخراج ویژگی و مرحله ششم کلاس بند چندتایی می باشد .

شکل ۱-۱ - بلوک دیاگرام الگوریتم پیشنهادی

#### ۱۲.۴ تغییر نرخ نمونهبرداری سیگنال ورودی

با توجه به آنکه طیف فرکانسی زیر ۱۳۰۰ هرتز طیفی است که توانالهای ناشی از ماشینآلات داخلی کشتی در آن غالب هستند (شکل ۲-۴) [۱]. در الگوریتم پیشنهاد شده ، بازه طیفی مورد استفاده ، فرکانس‌های پایین‌تر از ۱۳۰۰ هرتز می‌باشد . ازاینرو نرخ نمونهبرداری سیگنال را به ۲۵۶۰ هرتز تغییر می‌دهیم .



شکل ۲-۴- طیف فرکانسی یک شناور نمونه

#### ۲.۲.۴ تنظیم تغییر فاصله

در این مرحله برای تنظیم تغییر فاصله میان کشتی و دریافت‌کننده ، سیگنال ورودی را بر انرژی آن تقسیم می‌کنیم که سبب می‌شود سیگنال ورودی دارای انرژی واحد گردد [۱۶] .

#### ۳.۲.۴ محاسبه طیف

استخراج ویژگی از سیگنال‌های صوتی نیاز به پردازش سیگنال دارد . برخی از تکنیک‌های متداول پردازش سیگنال عبارتند از تبدیل فوریه ، تبدیل موجک ، تبدیل ویگنر-ویل<sup>۱</sup> ، تبدیل کپستروم<sup>۲</sup> و آنالیز جزء اصلی<sup>۳</sup> . تبدیل فوریه سیگنال ورودی را به حوزه فرکانس نگاشت می‌کند . علیرغم کاربردهای زیاد تبدیل فوریه سریع ،

<sup>۱</sup> Wigner-Ville Transform

<sup>۲</sup> Cepstrum Transform

<sup>۳</sup> Principal Componet Analysis (PCA)

معایبی نیز دارد . بعنوان مثال این تبدیل برای آنالیز سیگنال‌های گذرا مناسب نمی‌باشد . راه حل متداول رفع این عیب استفاده از تبدیل فوریه زمان کوتاه<sup>۴</sup> می‌باشد به دلیل آنکه در تبدیل فوریه زمان کوتاه سیگنال را در بازه زمانی کوتاه ، شبه ایستا<sup>۵</sup> فرض می‌کنیم .

سیگنال دریافتی در گیرنده سیگنالی آغشته به نویز می‌باشد . این نویز اغلب نویز سفید یا نویز گوسی فرض می‌شود . یکی از روش‌های حذف نویز قسمت‌بندی سیگنال به بخش‌هایی با فواصل زمانی کوتاه و سپس محاسبه طیف هر قسمت با استفاده از تبدیل فوریه و در نهایت متوسط‌گیری از طیف‌های حاصل می‌باشد . اگر نویز چند بخش با یکدیگر همبسته<sup>۶</sup> باشند ، این بخش‌بندی و متوسط‌گیری سبب کاهش تأثیر نویز ، حتی در صورت استفاده از همپوشانی<sup>۷</sup> می‌گردد .

با توجه به توضیحات گفته شده در بالا ، ابتدا سیگنال ورودی را به بخش‌هایی با طول ۲۵۶ بدون همپوشانی تقسیم کرده ، سپس این بخش‌ها را در یک پنجره همینگ<sup>۸</sup> با همین طول ضرب می‌کنیم . شکل ۳-۴ یک پنجره همینگ با طول ۳۲ را نشان می‌دهد . اکنون تابع خودهمبستگی آنرا با استفاده از رابطه (۱-۴) و (۲-۴)

[۳۵] بدست می‌آوریم .

$$R_{xx}(m) = \begin{cases} \sum_{n=1}^{N-m-1} x_{n+m} x_n^* & m > 0 \\ -R_{xx}^* & m < 0 \end{cases} \quad (1-4)$$

$$c(m) = R_{xx}(m-N) \quad m = 1, \dots, 2N-1 \quad (2-4)$$

در این روابط  $x$  سیگنال ورودی ،  $c$  سیگنال خروجی موردنظر و  $N$  طول سیگنال

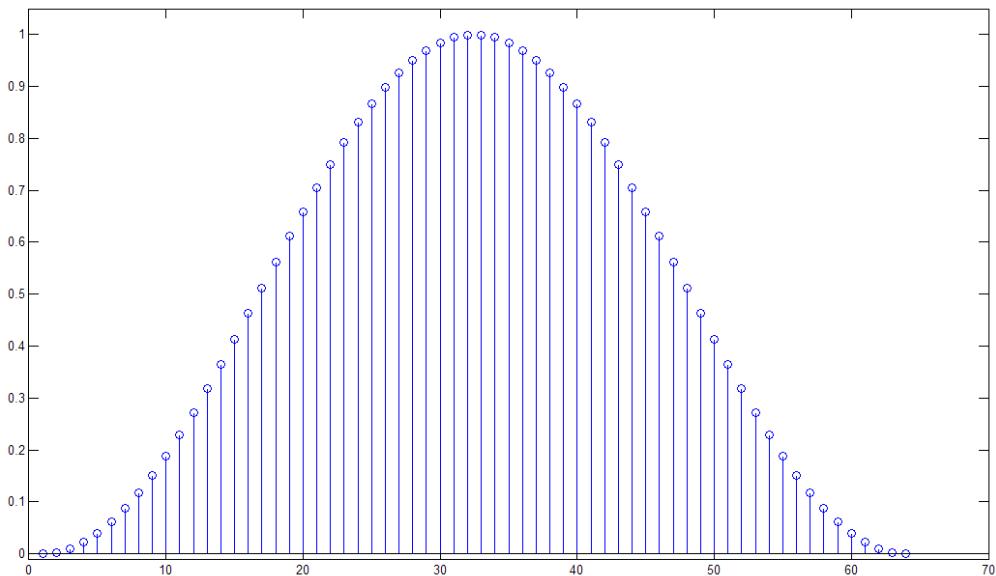
<sup>۴</sup> Short time Fourier Transform (STFT)

<sup>۵</sup> quasi-stationary

<sup>۶</sup> Correlation

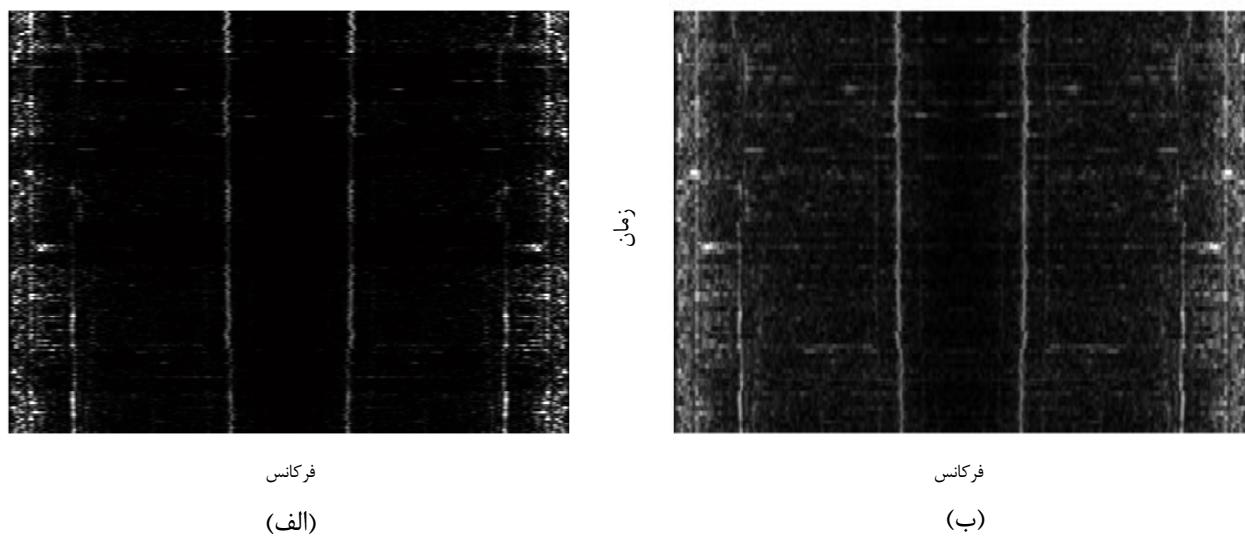
<sup>۷</sup> Overlapping

<sup>۸</sup> Hanning



شکل ۴-۳- یک پنجره همینگ با طول ۶۴

خروجی  $C$  برابر ۵۱۱ است . مزیت استفاده از این روابط قبل از محاسبه تبدیل فوریه سیگنال ورودی در شکل ۴-۴ ، اسپکتوگرام حاصل از نویز یکی از کلاس‌ها ، می‌توان مشاهده نمود . همان‌گونه که در شکل مشاهده می‌شود طیف حاصل بعداز اعمال تابع خود همبستگی دارای وضوح بیشتر و نویز کمتری است .



شکل ۴-۴- یک اسپکتوگرام نمونه (الف) با استفاده از تابع خودهمبستگی (ب) بدون استفاده از تابع خود همبستگی

طیف سیگنال خروجی از رابطه (۲-۴) را با رابطه (۳-۴) محاسبه می‌نماییم :

$$C(f) = \sum_{m=1}^N c(m) e^{-j\pi f m} \quad (3-4)$$

$c(m)$  سیگنال خود همبستگی ،  $C(f)$  طیف سیگنال ورودی و  $N$  طول داده ورودی است .

#### ۴.۲.۴. محاسبه ماتریس $H$

در این مرحله بردار  $S$  را با استفاده از رابطه زیر بدست می‌آوریم :

$$S_{i+1} = C_{i+1} * h + S_i \quad i = 0, 1, 2, \dots, K; K = \frac{N}{2} \quad (4-4)$$

(\*) کانولوشن ،  $h$  برداری با توزیع گوسی و طول معین که جهت هموارسازی به کار می‌رود .  $C_{i+1}$  طیف حاصل

از هر بخش از بخش‌بندی سیگنال ورودی است . به عبارت ساده‌تر داریم :

$$S_{i+1} = \text{طیف } 1 + \dots + \text{طیف } (i+1) + \dots + \text{طیف } N$$

ماتریس  $G$  را به صورت زیر تشکیل می‌دهیم :

$$G(i, 1:512) = S_i \quad i = 1, \dots, \frac{N}{2} \quad (5-4)$$

$i$  شماره سطر ،  $N$  طول داده ورودی است . بدلیل آنکه مقادیر ماتریس  $G$  در بازه  $[1, 512]$  قرار بگیرند تمام درایه-

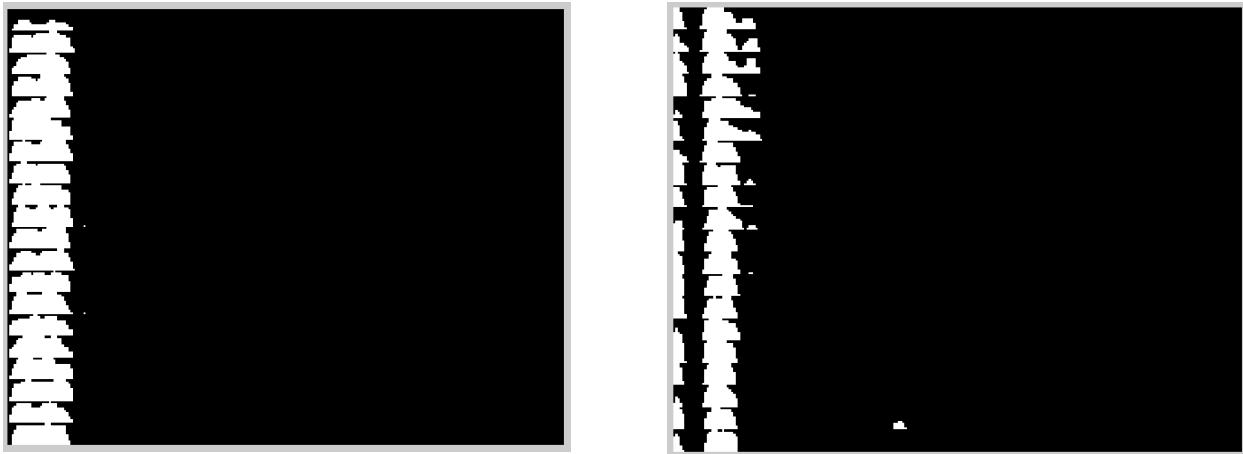
های ماتریس  $G$  را بر ماکریم مقدار آن تقسیم می‌کنیم ، داریم :

$$G = \frac{G}{\max(G)} \quad (6-4)$$

برای تبدیل ماتریس  $G$  به ماتریس  $H$  که یک ماتریس باینری است ، به صورت زیر عمل می‌کنیم :

$$H = \begin{cases} 1 & G(i,j) > \text{mean}(G) \\ 0 & G(i,j) < \text{mean}(G) \end{cases} \quad i = 1, \dots, \frac{N}{2}; j = 1, \dots, 512 \quad (7-4)$$

شکل ۵-۴ ماتریس  $H$  دو نمونه از کلاس‌ها را نشان می‌دهد . در این اشکال به دلیل تقارن موجود در طیف فرکانسی تنها نیمی از ماتریس  $H$  نشان داده شده است . ماتریس  $H$  را می‌توان به صورت یک تصویر باینری در نظر گرفت . ابتدا تصویر باینری  $H$  را سایش داده و سپس گسترش می‌دهیم . عمل بعدی پیش‌پردازش ، حذف ناحیه‌هایی با کمتر از ۲۰ پیکسل می‌باشد .



شکل ۴-۵- ماتریس  $H$  دو نمونه از کلاس‌ها

#### ۵.۲.۴. استخراج ویژگی

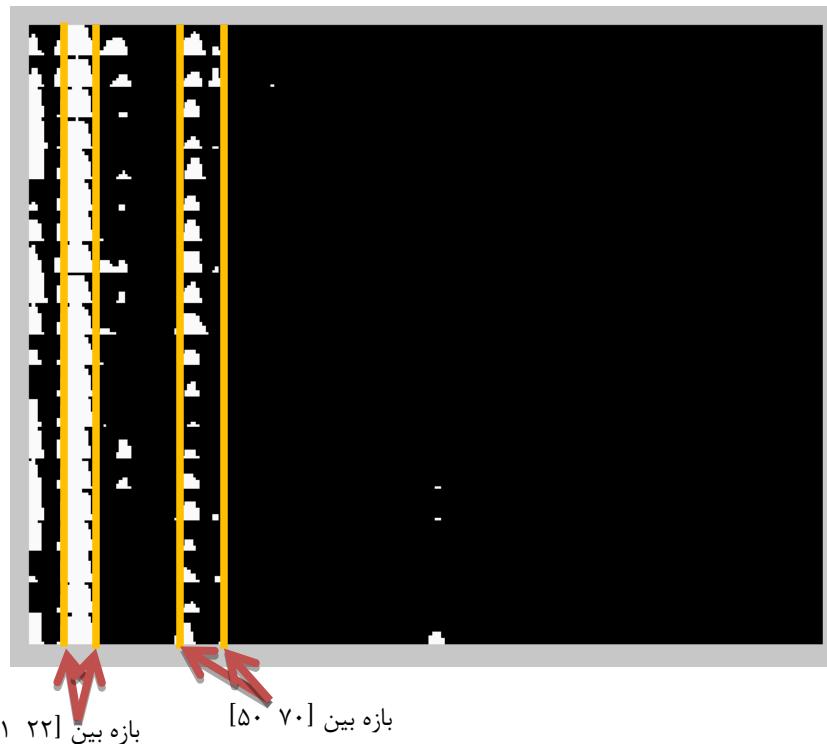
در این مرحله که مرحله پنجم از مراحل الگوریتم پیشنهاد شده می‌باشد برای استخراج ویژگی‌ها به این صورت عمل می‌نماییم که ابتدا مقادیر طیف در بازه‌های فرکانسی  $[950 \text{ } 1050]$  و  $[500 \text{ } 600]$  ماتریس  $H$  را در یک ماتریس دیگری به نام  $Q$  که یک ماتریس با ابعاد ماتریس  $H$  و مقدار تمام آرایه‌های آن صفر، قرار می‌دهیم. سپس فواصل بینی<sup>۹</sup> (محور افقی) زیر را در نظر می‌گیریم.

- بازه بین  $[1 \text{ } 5]$
- بازه بین  $[2 \text{ } 30]$
- بازه بین  $[2 \text{ } 45]$
- بازه بین  $[11 \text{ } 22]$
- بازه بین  $[14 \text{ } 34]$
- بازه بین  $[18 \text{ } 60]$

<sup>۹</sup> Bin

- بازه بین [٣٠ ٥٦]
- بازه بین [٥٠ ٧٠]
- بازه بین [٧٠ ١٠٠]
- بازه بین [١٩٣ ٢٠٨]

این نکته را باید در نظر داشت که این فواصل بین‌ها را با طول ۵۱۲ در نظر گرفته‌ایم . در صورت تغییر طول مثلاً ۶-۴ ، بازه بین [٥٠ ٧٠] در ۵۱۲ به بازه بین [٣٥ ٢٥] تبدیل می‌شود . دو نمونه انتخاب بین در شکل ۶-۴ آورده شده است .



شکل ۶-۴- یک نمونه انتخاب بین

پس از تعیین بازه‌های ذکر شده در بالا ، تعداد پیکسل‌ها با مقدار یک در این فواصل و همچنین تعداد کل پیکسل‌ها با مقدار یک در ماتریس  $Q$  را تعیین می‌نماییم آنگاه مقادیر بدست آمده را بر از فواصل تعیین شده را

بر تعداد کل پیکسل‌ها با مقدار یک تقسیم و در کنار هم در یک بردار قرار می‌دهیم . در نهایت مقادیر بردار را بر ماکزیمم مقدار بردار تقسیم می‌نماییم . بردار حاصل یک بردار با طول ۱۱ است .

#### ۶.۲.۴. کلاس‌بند

جهت کلاس‌بندی داده‌ها نیاز به استفاده از کلاس‌بند می‌باشد . در این پایان‌نامه از یک کلاس‌بند عصبی جهت طبقه‌بندی سیگنال ورودی استفاده می‌شود . قبل از اینکه جزئیات مربوط به شبکه عصبی<sup>۱۰</sup> مورد استفاده را ذکر نماییم ، لازم میدانیم مختصری راجع به شبکه عصبی توضیح داده شود .

#### ۱.۶.۲.۴. شبکه عصبی چیست؟

یک شبکه عصبی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد . این سیستم از شمار زیادی عناصر پردازشی بهم پیوسته نام نرون<sup>۱۱</sup> تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند . شبکه‌های عصبی ، نظیر انسانها ، جهت یادگیری آموزش داده می‌شوند . یک شبکه عصبی برای انجام فعالیت‌های مشخص ، مانند تشخیص الگوها و دسته بندی اطلاعات ، در طول یک فرآیند یادگیری ، تنظیم می‌شود . در سیستم‌های زیستی یاد گیری با تنظیماتی در اتصالات سیناپسی که بین اعصاب قرار دارد همراه است . این روش در شبکه‌های عصبی نیز به کار می‌رود . شبکه‌های عصبی میتوانند برای استخراج الگوها و شناسایی روش‌هایی که آگاهی از آنها برای انسان و دیگر تکنیک‌های کامپیوتری بسیار پیچیده و دشوار است به کار گرفته شود . یک شبکه عصبی آموزش دیده می‌تواند به عنوان یک آنالیزکننده در مقوله اطلاعاتی که برای تجزیه و تحلیل به آن داده شده به حساب آید . مزیتهاي دیگر آن شامل موارد زیر می‌شود :

- قابلیت یادگیری انطباق‌پذیر :

قابلیت یادگیری بر اساس اطلاعات داده شده برای آموزش است .

<sup>۱۰</sup> Neural Network

## ۱۱ Neuron

### ۱۲ عملکرد به هنگام •

محاسبات شبکه عصبی می‌تواند به صورت موازی انجام شود.

برخی مسائل مناسب برای یادگیری شبکه‌های عصبی را نیز می‌توان به صورت زیر خلاصه نمود:

- خطای داده‌های آموزشی وجود داشته باشد و نظیر مسائلی که داده‌های آموزشی دارای نویز حاصل از داده‌های سنسورها مانند میکروفون‌ها هستند.

مواردی که نمونه توسط مقادیر زیادی زوج ویژگی-مقدار نشان داده شده باشند.

• زمان کافی برای یادگیری وجود داشته باشد.

برخی معایب شبکه عصبی نیز به قرار زیر می‌باشد:

- قواعد معینی برای طراحی شبکه عصبی جهت یک کاربرد اختیاری وجود ندارد.
- آموزش شبکه ممکن است مشکل و یا حتی عیر ممکن باشد.
- پیش‌بینی عملکرد آینده شبکه عصبی به سادگی امکان‌پذیر نیست.

### ۲.۶.۲.۴ ساختار شبکه عصبی

اجزای سازنده شبکه عصبی، نرون‌ها، لایه‌ها و وزن‌ها می‌باشد. نحوه عملکرد شبکه عصبی وابسته به ارتباط بین اجزا است. هر نرون شامل یک تابع فعال‌ساز<sup>۱۳</sup> یا همان عضو تصمیم‌گیرنده است. ارتباط بین نرون‌ها توسط خطوطی صورت می‌پذیرد که دارای وزن مخصوص به خود است. به عبارتی هر نرون شامل چند خط ورودی (حاصل ضرب متغیر ورودی در وزن مخصوص به آن) و یک خروجی ناشی از تابع فعال‌ساز می‌باشد. یک مسئله مهم در شبکه عصبی تعیین مناسب اوزان می‌باشد به دلیل اینکه اوزان بیانگر چگونگی ارتباط بین مؤلفه‌های

<sup>۱۲</sup> Real-time

<sup>۱۳</sup> Activation function

ورودی و مؤلفه‌های خروجی بر حسب نوع تابع فعال‌ساز می‌باشد بنابراین برای تعیین وزن‌ها در هر شبکه عصبی مرحله‌ای به نام مرحله آموزش داریم . در مرحله آموزش مباحثی نظیر استراتژی کلی یادگیری (مانند آموزش با ناظر<sup>۱۴</sup> یا آموزش بدون ناظر) و یا روش‌های مختلف یادگیری (مانند پس انتشار خطا<sup>۱۵</sup> یا تصحیح خطا<sup>۱۶</sup> یا ...) وجود دارد . در حالت کلی شبکه عصبی از سه لایه تشکیل یافته است :

- لایه ورودی

وظیفه دریافت اطلاعات خام ورودی به شبکه را دارد .

- لایه(لایه‌های) مخفی

عملکرد این لایه به وسیله ورودی‌ها و وزن‌های ارتباطی لایه ورودی با این لایه تعیین می‌گردد .

- لایه خروجی

نحوه عملکرد واحد خروجی وابسته به عملکرد لایه مخفی و وزن‌های ارتباطی لایه مخفی با این لایه دارد .

هر دو لایه مجزا در شبکه‌های عصبی توسط وزن‌ها به یکدیگر متصل هستند . همچنین شبکه عصبی دارای ۳ نوع اتصال وزنی : پیشرو ، پسخورد و جانبی می‌باشد . در شبکه عصبی پیشرو<sup>۱۷</sup> ، نرون‌ها در چند لایه کنار هم قرار گرفته‌اند . در این شبکه خروجی هر لایه فقط ورودی لایه بعد می‌باشد و سیگنال‌ها تنها رو به جلو حرکت می‌کنند . بیشترین کاربرد این شبکه عصبی برای برقراری ارتباط میان داده‌هایی است که به ارتباط میان داده اطمینان داریم ولی بدست آوردن این ارتباط بسیار مشکل می‌باشد . بنابراین با استفاده از این شبکه عصبی با روش یادگیری پس انتشار خطا می‌توان ، ارتباط میان آنها بدست آورد .

<sup>۱۴</sup> Supervised learning

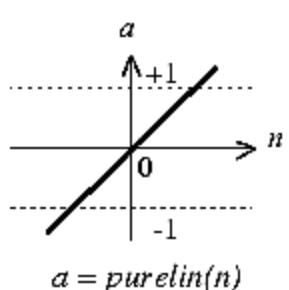
<sup>۱۵</sup> Back Propagation Error

<sup>۱۶</sup> Error Correction

<sup>۱۷</sup> Feedforward Neural Network

توابع فعال سازی که برای این نوع شبکه عصبی معمولاً استفاده می‌شوند عبارتند از :

- تابع فعال ساز Purline (خطی)

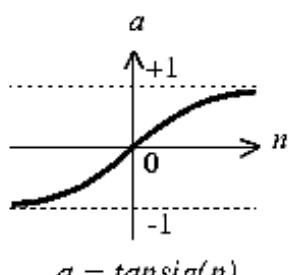


در این تابع فعال ساز ، رابطه خطی میان ورودی و خروجی برقرار است .

$$Purlin(n) = n \quad (8-4)$$

شکل ۴-۷-تابع فعال ساز خطی [۳۵]

- تابع فعال ساز Tan-Sigmoid (تanzانت هایپربولیک)

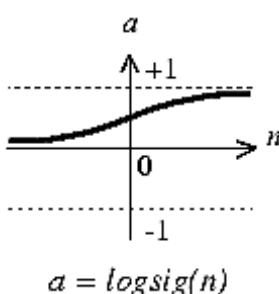


در این نوع تابع فعال ساز ، رابطه نمایی بین ورودی و خروجی برقرار می‌باشد .

$$tansig(n) = \frac{1}{1+\exp(-n)} - 1 \quad (9-4)$$

شکل ۴-۸-تابع فعال ساز نمایی [۳۵]

- تابع فعال ساز Log-Sigmoid (لگاریتمی)



در این تابع فعال ساز ، رابطه لگاریتمی میان ورودی و خروجی برقرار است .

$$\logsig(n) = \frac{1}{1+\exp(-n)} \quad (10-4)$$

شکل ۴-۹-تابع فعال ساز لگاریتمی [۳۵]

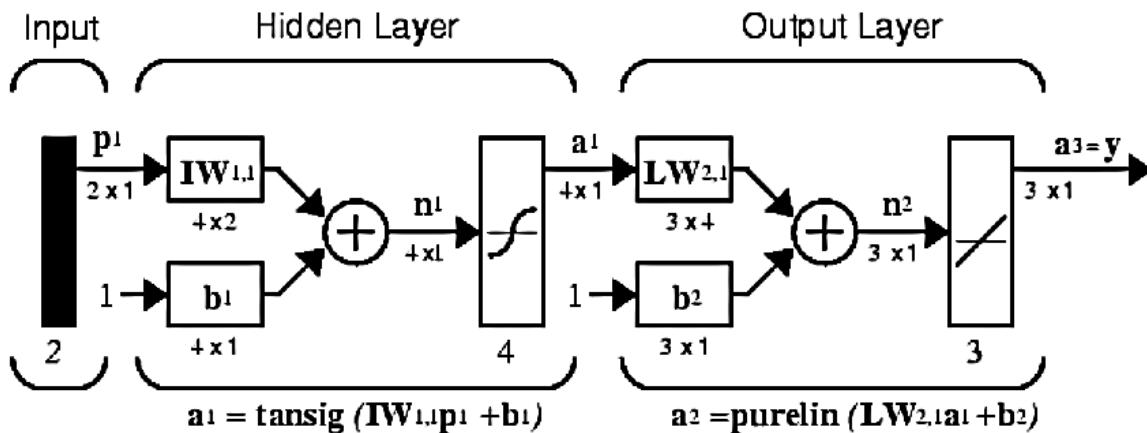
ممولاً در این نوع شبکه عصبی پیش رو از چگونگی ارتباط میان ورودی و خروجی دقیقاً آگاهی نداریم ، بنابراین

توصیه شده است [۳۶-۳۷] که در بایه اول از توابع فعال ساز تانژانت هایپربولیک یا لگاریتمی استفاده گردد

تا بردارنده ارتباط غیرخطی احتمالی میان ورودی و خروجی باشد و در لایه آخر از تابع فعال ساز خطی استفاده گردد تا بازه خروجی بزرگتر از ۱ یا کوچکتر از ۱- را پاسخگو باشد .

استراتژی یادگیری در این نوع شبکه عصبی رو به جلو به صورت آموزش با ناظر میباشد یعنی در مرحله آموزش هر ورودی به همراه خروجی متناظر با آن (به صورت زوجهای مرتب) به شبکه عصبی اعمال میگردد و شبکه با روش آموزش پس انتشار خطا آموزش داده یا به معنای دیگر وزن های آن تعیین میشود .

در روش آموزشی پس انتشار خطا ، ابتدا سیگنال ورودی به شبکه اعمال میشود ، این سیگنال رو به جلو و لایه به لایه پیشروی نموده و خروجی بدست میآید . در این حالت با توجه به خروجی متناظر با ورودی اعمال شده و خروجی حاصل از شبکه عصبی خطا محاسبه میگردد . خطا را به صورت عکس ، از لایه خروجی رو به عقب اعمال نموده و مقدار خطای مربوط به هر نرون در هر لایه محاسبه میشود . این خطا جهت تغییر اوزان و درجهت کاهش میانگی مربعات خطا<sup>۱۸</sup> مورد استفاده قرار میگیرد . شکل ۱۰-۴ یک شبکه عصبی FFBP دو لایه ، با ۴ نرون در لایه مخفی و ۳ نرون در لایه خروجی ، را نشان میدهد .



شکل ۱۰-۴ - شبکه عصبی پیشرو دو لایه : لایه مخفی با ۴ نرون و لایه خروجی با ۳ نرون

<sup>۱۸</sup> Mean Squar Errorr

با توجه به موارد ذکر شده ، کلاس‌بندی که در این پایان‌نامه طراحی شده است ، یک شبکه عصبی FFBP دو لایه می‌باشد که ۷ نرون در لایه میانی و ۷ نرون معادل با ۷ کلاس خروجی در لایه خروجی به کار گرفته شده-اند . تابع فعال‌ساز میانی از نوع تانژانت هایپربولیک و لایه خروجی از نوع خطی می‌باشد .

# فصل پنجم

شبیه‌سازی و ارزیابی

نتایج

### ۱.۵ مقدمه :

در فصل ۵ ابتدا بانک داده مورد استفاده در پیاده سازی الگوریتم پیشنهادی را به تفصیل توضیح خواهیم داد . سپس نتایج حاصل از پیاده‌سازی و تأثیر تغییر برخی مشخصات در کارایی الگوریتم پیشنهادی را مورد بررسی قرار می‌دهیم و در انتهای نیز به ارزیابی کارایی الگوریتم پیشنهاد شده با دو روش موجود دیگر می‌پردازیم .

### ۲.۵ بانک داده مورد استفاده :

بانک داده جمع‌آوری شده متشکل از صدای قایق‌ها ، کشتی‌های سطحی ، زیردریایی و دلفین می‌باشد . در تقسیم‌بندی بانک داده مورد استفاده به ترتیب زیر عمل نموده‌ایم :

- کلاس اول

نویز زیرآب ناشی از قایق که شامل ۱۰ فایل صوتی است . ۷ فایل را جهت آموزش شبکه عصبی و ۳ فایل را جهت تست به کار برده‌ایم .

- کلاس دوم

نویز زیرآب کشتی سطحی و متوسط اول با وزن ۱۲۴۸ تن که شامل ۲۰ فایل صوتی است . از ۱۴ داده جهت آموزش شبکه عصبی و از ۶ فایل صوتی را جهت تست الگوریتم پیشنهادی استفاده نموده‌ایم .

- کلاس سوم

متشکل از نویز زیرآب منتشره از کشتی سطحی و متوسط دوم دارای وزن ۳۶۶۰ تن با ۲۰ داده صوتی می‌باشد . ۱۴ داده صوتی برای آموزش و ۶ داده صوتی برای تست مورد استفاده قرار گرفته‌اند .

- کلاس چهارم

حاوی ۲۰ داده صوتی از نویز کشته سطحی و متوسط سوم با وزن ۲۵۹۲ تن می‌باشد. ۱۴ داده از آن جهت پروسه یادگیری و ۶ داده از آن برای پروسه تست به کار رفته است.

• کلاس پنجم

نویز انتشاری زیرآب کشته سطحی و سنگین با وزن ۳۵۵۷۳ تن متشکل از ۲۰ سیگنال صوتی است.

۱۴ سیگنال نویز انتشاری برای آموزش و ۶ سیگنال جهت تست استفاده شده‌اند.

• کلاس ششم

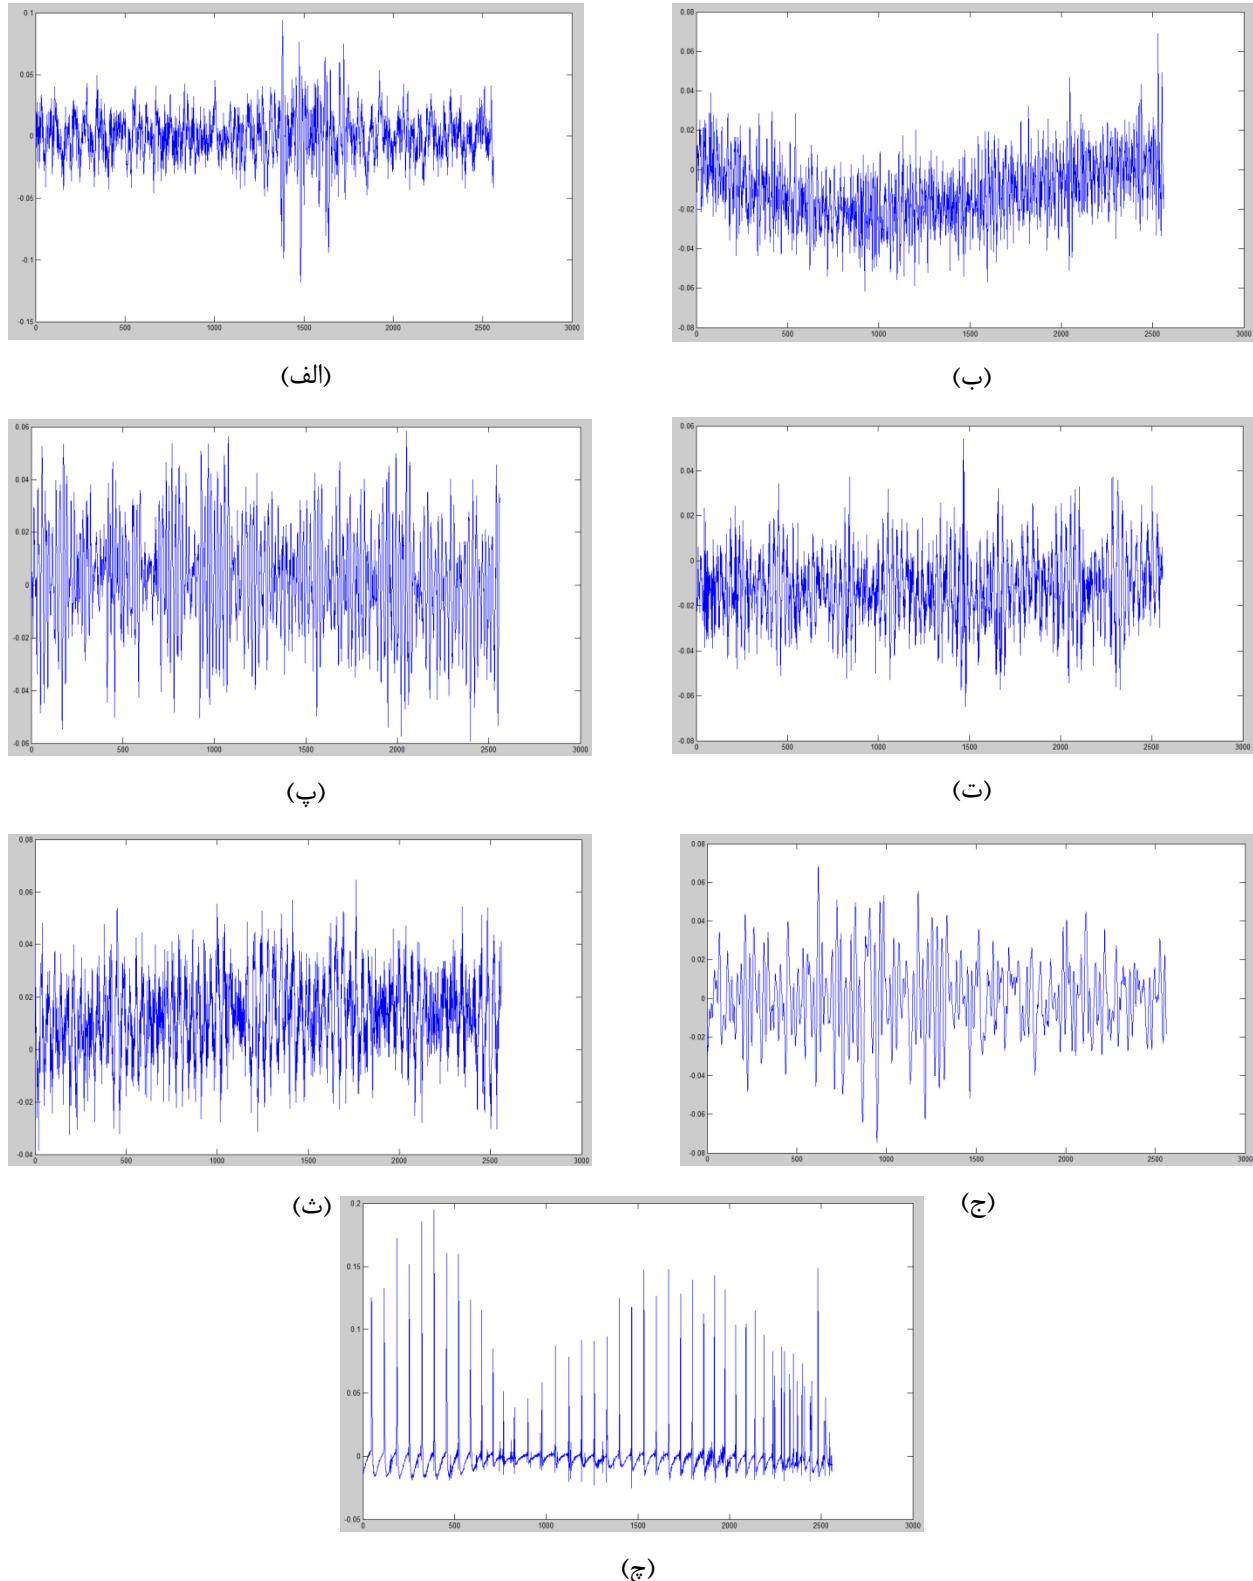
شامل ۲۰ فایل از نویز زیرآب منتشر شده از زیردریایی می‌باشد. ۱۴ داده جهت آموزش و ۶ داده برای تست الگوریتم پیشنهاد شده به کار بردہ شده‌اند.

• کلاس هفتم

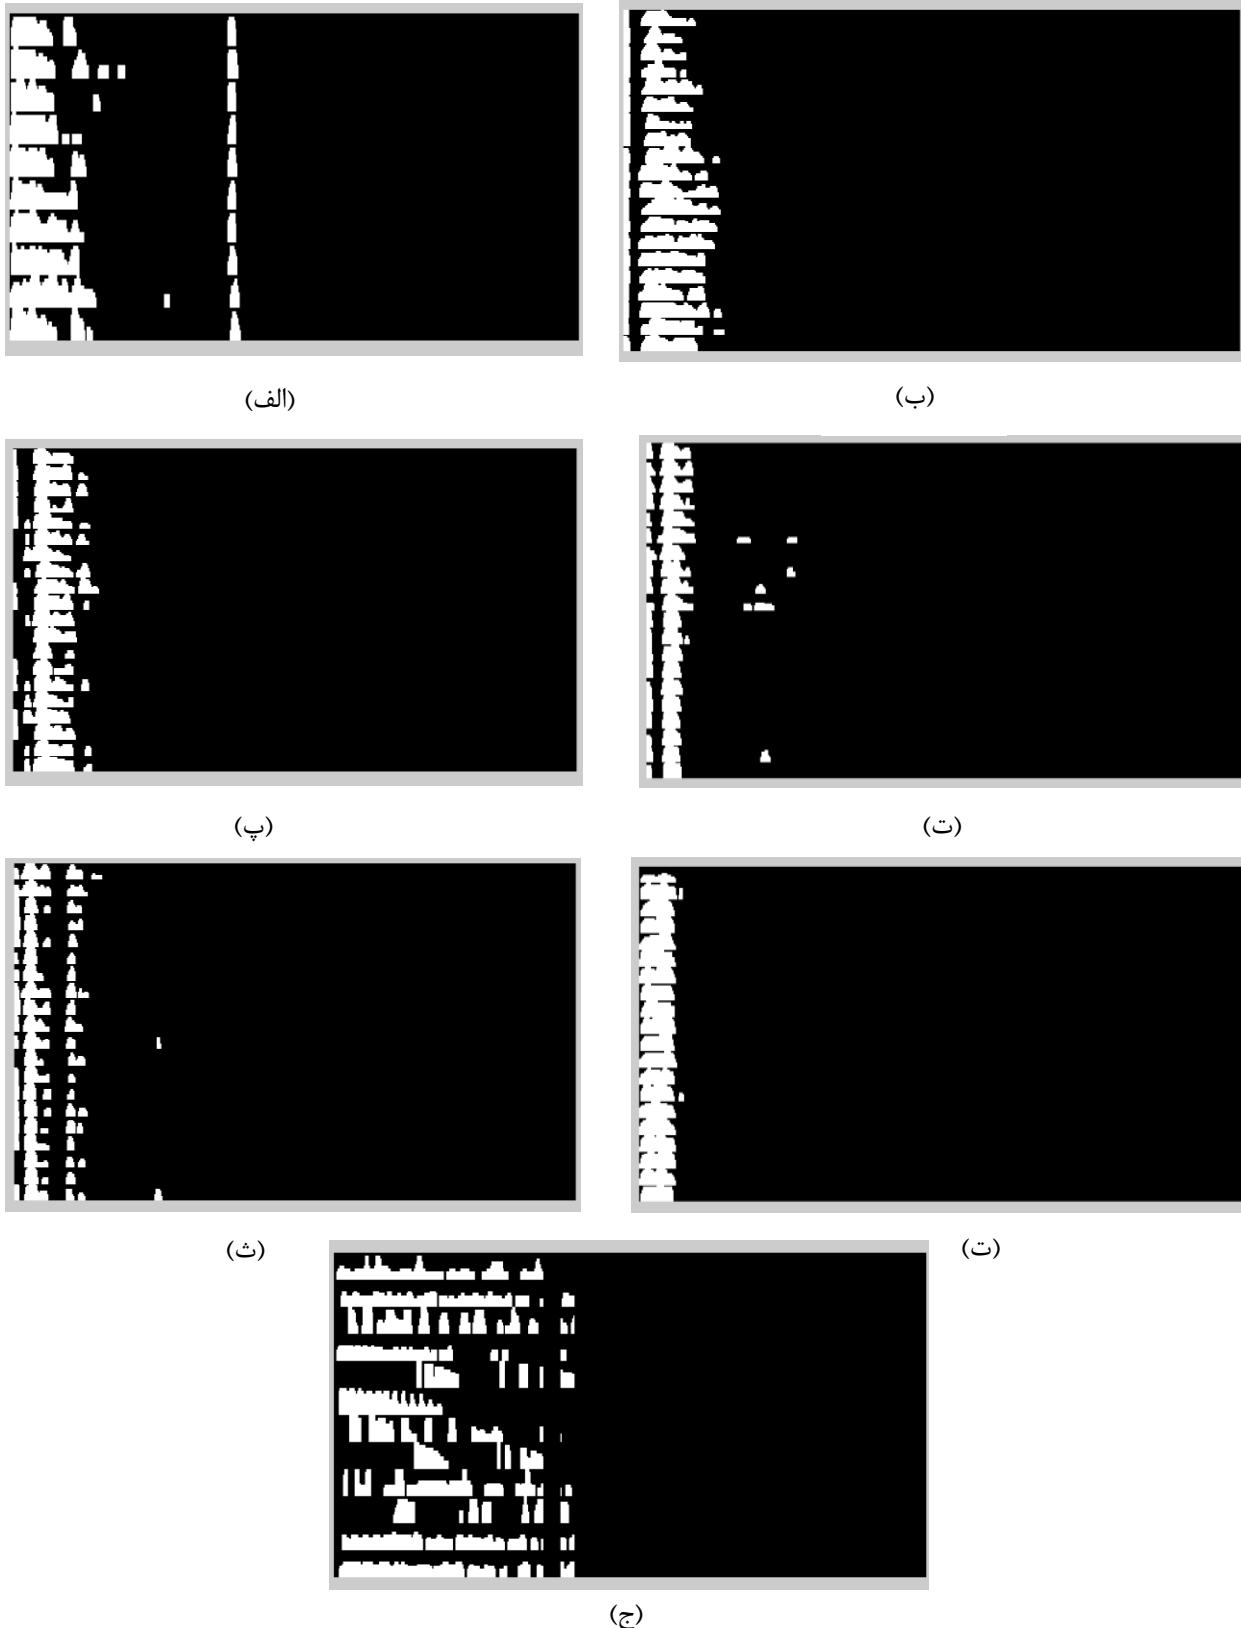
این کلاس از ۱۲ صوت زیرآب دلفین تشکیل یافته است. ۷ داده را برای فرآیند یادگیری و ۵ داده را برای فرآیند آزمایش استفاده کرده‌ایم.

جدول ۵-۱- بانک داده مورد استفاده

تعداد داده کلاس	تعداد داده‌های آموزش	تعداد داده‌های تست	تعداد مجموع داده‌ها
کلاس اول	۷	۳	۱۰
کلاس دوم	۱۴	۶	۲۰
کلاس سوم	۱۴	۶	۲۰
کلاس چهارم	۱۴	۶	۲۰
کلاس پنجم	۱۴	۶	۲۰
کلاس ششم	۱۴	۶	۲۰
کلاس هفتم	۷	۵	۱۲



شکل ۱-۵- نمونه‌های سیگنالی از (الف) کلاس اول (ب) کلاس دوم (پ) کلاس سوم (ت) کلاس چهارم(ث) کلاس پنجم (ج) کلاس ششم (چ) کلاس هفتم



شکل ۵-۲- ماتریس‌های  $H$  کلاس‌های (الف) اول (ب) دوم (پ) سوم (ت) چهارم (ت) پنجم (ث) ششم (ج) هفتم

تمام داده‌های کلاس‌های مختلف دارای طول ۲۵۶۰ با فرکانس نمونه‌برداری ۰۲۵۶ هرتز می‌باشند. در جدول ۱-۵ اطلاعات مربوط به تقسیم‌بندی داده‌های موجود آورده شده است. داده‌های گروه دوم تا پنجم از پژوهشکده مهندسی جهاد کشاورزی تهیه شده است. در شکل ۱-۵ نمونه‌ای از سیگنال هر کلاس و در شکل ۳-۵ ماتریس  $H$  مربوط به تمام داده‌ها با کلاس‌های مربوطه آورده شده است.

### ۵.۳.۵. نتایج حاصل از شبیه‌سازی الگوریتم پیشنهادی

در این بخش به ارزیابی کارایی الگوریتم پیشنهادی با انجام چند آزمایش می‌پردازیم. در آزمایش اول طول بخش‌بندی سیگنال ورودی را تغییر داده و نتایج آن را بررسی می‌نماییم. در آزمایش دوم به بررسی تأثیر مقادیر مختلف آستانه، جهت ایجاد ماتریس  $H$ ، بر کارایی الگوریتم پیشنهادی پرداخته می‌شود. در آزمایش آخر نیز میزان کارایی الگوریتم پیشنهادی را با دو روش موجود فرآکتال و متوسط‌گیری طیفی مقایسه می‌شود.

### ۱.۳.۵. تغییر طول بخش‌بندی سیگنال ورودی

یکی از مشخصات الگوریتم پیشنهادی طول بخش‌بندی سیگنال می‌باشد که در بخش ۳-۲-۴ به آن اشاره شد. در این قسمت در نظر داریم تغییرات کارایی الگوریتم پیشنهادی را با توجه به تغییرات طول بخش‌بندی سیگنال ارزیابی نماییم. بررسی را با طول‌های ۱۲۸، ۲۵۶ و ۵۱۲ بدون همپوشانی انجام داده و نتایج درصد نرخ شناسایی آن در جدول ۲-۵ آورده شده است. این نتایج در سیگنال به نویز ۱۰ دسیبل و با ۵۰ تکرار بدست آمده‌اند. با توجه به مقادیر جدول ۲-۵ میزان شناسایی کلاس‌های اول، سوم، چهارم و هفتم مستقل از تغییر طول بخش‌بندی می‌باشد و جهت مقایسه بهتر، در شکل‌های ۲-۵-الف تا ج به ترتیب نمونه‌های ماتریس  $H$  کلاس اول با طول‌های متفاوت با نویز و بدون نویز آورده شده است. اما میزان شناسایی کلاس‌های دوم، پنجم و ششم تحت تأثیر تغییر طول بخش‌بندی می‌باشد. بعنوان مثال در بخش‌بندی سیگنال با طول ۱۲۸، ۱۲۷ و ۸۸.۶٪ داده از کلاس دوم را به عنوان کلاس سوم شناسایی نموده در حالیکه با افزایش طول بخش‌بندی صحبت شناسایی کلاس دوم افزایش یافته است. با جمع نرخ‌های شناسایی کلاس‌های مختلف با طول بخش‌بندی متفاوت، میزان شناسایی صحیح ۷۲.۳٪ و میزان شناسایی ناصحیح ۲۶.۹٪ برای بخش‌بندی با طول ۱۲۸،

جدول ۲-۵- میزان شناسایی کلاس‌ها با تغییر طول بخش‌بندی سیکنال (الف) طول ۱۲۸ (ب) طول ۲۵۶ (پ) طول ۵۱۲

کلاس هفتم	کلاس ششم	کلاس پنجم	کلاس چهارم	کلاس سوم	کلاس دوم	کلاس اول	کلاس تشخیصی کلاس ورودی
۰	۰	۰	۰	۰	۰	٪۱۰۰	کلاس اول
٪۱	۰	۰	۰	٪۸۸.۶۷	٪۹.۶۷	۰	کلاس دوم
٪۰.۳۳	۰	۰	۰	٪۹۹.۶۷	۰	۰	کلاس سوم
۰	٪.۳	۰	٪.۹۱	٪.۶	۰	۰	کلاس چهارم
٪۱۲.۶۷	٪۸.۶۷	٪.۵۳	٪.۰.۳۳	٪.۶.۳۳	۰	٪.۱۶.۶۷	کلاس پنجم
۰	٪.۷۳	٪.۲۴.۶۷	۰	۰	۰	۰	کلاس ششم
٪۸۰	۰	۰	۰	۰	۰	٪.۲۰	کلاس هفتم

(الف)

کلاس هفتم	کلاس ششم	کلاس پنجم	کلاس چهارم	کلاس سوم	کلاس دوم	کلاس اول	کلاس تشخیصی کلاس ورودی
٪.۰.۶۷	۰	۰	۰	۰	۰	٪۹۹.۳۳	کلاس اول
٪۰.۳۳	۰	۰	۰	٪.۴.۳۳	٪۹۳.۶۷	۰	کلاس دوم
٪۳.۶۷	۰	۰	۰	٪.۹۴	٪.۰.۶۷	۰	کلاس سوم
۰	٪.۰.۳۳	۰	٪.۹۹	۰	٪.۰.۶۷	۰	کلاس چهارم
٪۱	٪.۰.۳۳	٪.۹۴.۶۷	۰	۰	٪.۰.۶۷	٪.۰.۳۳	کلاس پنجم
۰	٪.۱۰۰	۰	۰	۰	۰	۰	کلاس ششم
٪۹۹.۶	۰	۰	۰	۰	٪.۰.۴	۰	کلاس هفتم

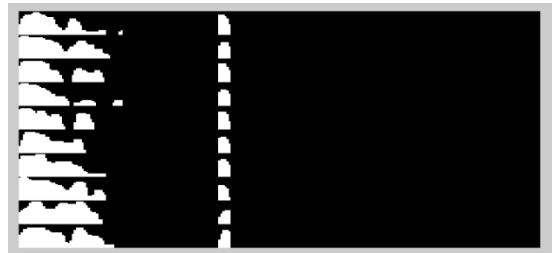
(ب)

کلاس هفتم	کلاس ششم	کلاس پنجم	کلاس چهارم	کلاس سوم	کلاس دوم	کلاس اول	کلاس تشخیصی کلاس ورودی
۰	۰	۰	۰	۰	۰	٪۱۰۰	کلاس اول
٪۱	۰	۰	۰	٪.۵.۳۳	٪۹۴.۶۷	۰	کلاس دوم
۰	۰	۰	۰	٪.۹۶.۶۷	٪.۳	۰	کلاس سوم
۰	٪.۰.۶۷	٪.۰.۳۳	٪.۹۸.۳۳	۰	۰	٪.۰.۳۳	کلاس چهارم
٪۳	٪.۰.۳۳	٪.۸۵	۰	۰	۰	۰	کلاس پنجم
۰	٪.۱۰۰	۰	۰	۰	۰	۰	کلاس ششم
٪۸۰.۴	۰	۰	۰	۰	۰	٪.۱۹.۶	کلاس هفتم

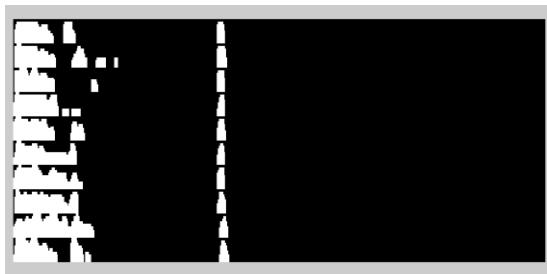
(پ)



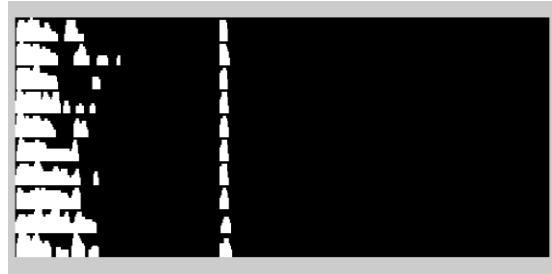
(الف)



(ب)



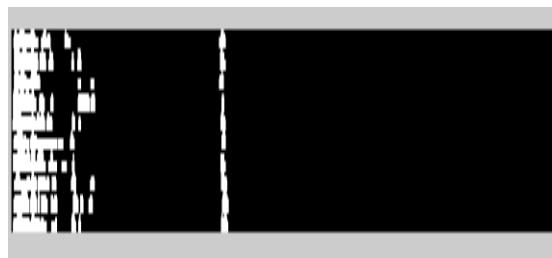
(پ)



(ت)



(ث)

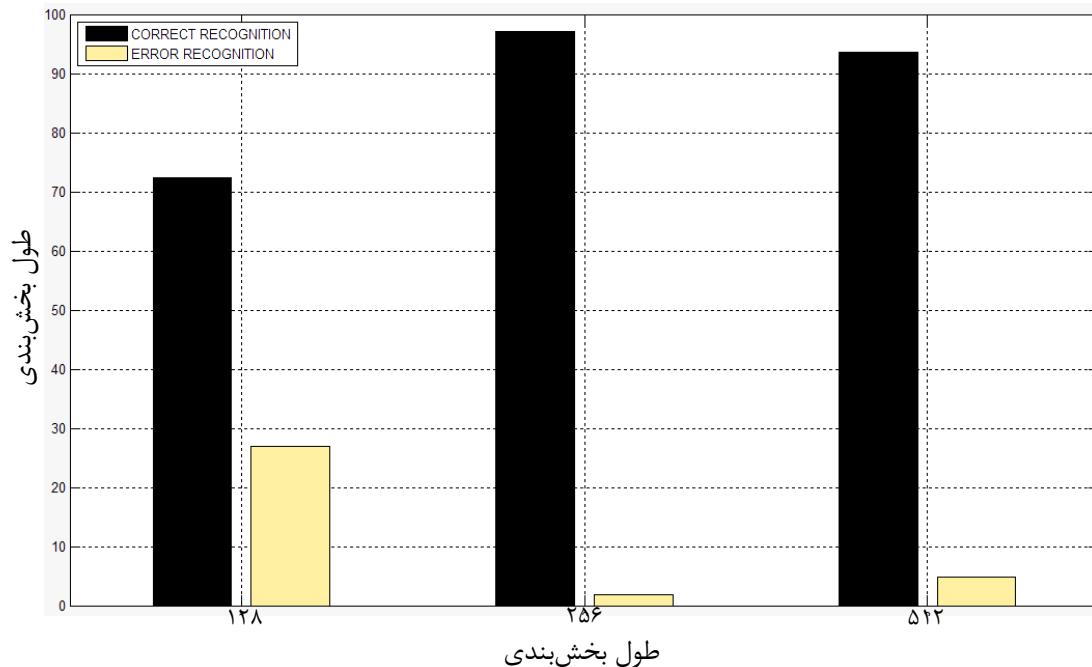


(ج)

شکل ۳-۵- نمونه‌های ماتریس  $H$  کلاس اول با طول‌های بخش بندی‌بندی متفاوت (الف) ماتریس  $H$  با طول بخش بندی سیگنال ۱۲۸ و بدون نویز (ب) ماتریس  $H$  با طول بخش بندی سیگنال ۱۲۸ و سیگنال به نویز ۱۰ دسیبل (پ) ماتریس  $H$  با طول بخش بندی سیگنال ۲۵۶ و بدون نویز (ت) ماتریس  $H$  با طول بخش بندی سیگنال ۲۵۶ و سیگنال به نویز ۱۰ دسیبل (ث) ماتریس  $H$  با طول بخش بندی سیگنال ۵۱۲ و بدون نویز (ج) ماتریس  $H$  با طول بخش بندی سیگنال ۵۱۲ و سیگنال به نویز ۱۰ دسیبل

میزان شناسایی صحیح ۹۷.۱۸٪ و شناسایی نادرست ۱.۹۱٪ برای بخش بندی با طول ۲۵۶ و در نهایت نرخ شناسایی صحیح ۹۳.۵۸٪ و نرخ شناسایی نادرست ۴.۸۰٪ برای بخش بندی با طول ۵۱۲ حاصل می‌گردد که نمودار مربوط به آن در شکل ۴-۵ آمده است . با در نظر گرفتن این نتایج و مقادیر جدول ۲-۵ و شکل ۳-۵ می‌توان به این صورت نتیجه‌گیری کرد که با کاهش طول بخش بندی ماتریس  $H$  مربوط به کلاس‌های اول ،

سوم، چهارم و هفتم منحصر بفرد میماند در صورتیکه ماتریس  $H$  مربوط به کلاس دوم به ماتریس  $H$  کلاس سوم شبیه‌تر و ماتریس  $H$  کلاس‌های پنجم و ششم نیز به یکدیگر همانندتر می‌شوند و حاصل آن کاهش نرخ شناسایی و افزایش تشخیص نادرست می‌باشد. با افزایش طول بخش‌بندی به ۵۱۲ میزان شباهت ماتریس  $H$  کلاس‌ها به یکدیگر کمتر می‌شود که در این ارتباط افزایش میزان شناسایی کلاس دوم را داریم، در صورتیکه نویزپذیری سیستم پیشنهادی نیز افزایش می‌یابد. تأثیر افزایش نویزپذیری غالب‌تر از کمی کاهش شباهت ماتریس  $H$  کلاس‌ها بوده و نتیجتاً میزان شناسایی اندکی کاهش می‌یابد. این مطلب در کاهش ۳.۶ درصدی نرخ شناسایی صحیح مجموع و افزایش ۲.۸۹ درصدی شناسایی نادرست از بخش‌بندی با طول ۲۵۶ به بخش‌بندی ۵۱۲ نمود می‌یابد بعنوان مثال کاهش نرخ شناسایی کلاس پنجم بدون افزایش تشخیص نادرست در این راستا می‌باشد.



شکل ۴-۵ نمودار شناسایی صحیح کل و شناسایی نادرست کل الگوریتم پیشنهادی با تغییر طول بخش‌بندی سیگنال ورودی

### ۲.۳.۵. تغییر مقدار آستانه جهت ایجاد ماتریس $H$

یکی از مهم‌ترین مراحل الگوریتم پیشنهادی ساخت ماتریس  $H$  می‌باشد. همانطور که در بخش ۳.۲.۴. گفته شد، برای ایجاد ماتریس باینری  $H$  نیاز به یک مقدار آستانه جهت اعمال به ماتریس  $G$  داریم. اکنون در این آزمایش به ارزیابی چگونگی تأثیر مقدارهای متفاوت آستانه در کارایی خواهیم پرداخت. آزمایش را با سه مقدار آستانه، مقدار متوسط تمام ماتریس  $G$  که به اختصار مقدار متوسط می‌نامیم، مقدار میانه تمام ماتریس  $G$  که به اختصار مقدار میانه می‌نامیم و مقدار آستانه ۰.۰۵ انجام می‌دهیم. این آزمایش دارای شرایط، طول بخش-بندی ۲۵۶ بدون همپوشانی، سیگنال به نویز ۱۰ دسیبل و ۵۰ تکرار الگوریتم پیشنهاد شده، می‌باشد. نتایج بدست آمده از این آزمایش را در جدول ۳-۵ لیست نموده‌ایم. همانطور که در جدول ۳-۵-الف قابل مشاهده است، انتخاب مقدار متوسط ماتریس  $G$  بعنوان آستانه برای باینری نمودن انتخاب مناسبی می‌باشد. بدلیل آنکه ماتریس  $H$  حاصل از این مقدار در سیگنال به نویز ذکر شده برای هر کلاس با توجه به نرخ شناسایی صحیح مجموع ۹۷.۱۸٪، ماتریس  $H$  یکتا و بطبع آن بردار ویژگی منحصر بفردی برای هر کلاس بدست می‌آید. این مقدار آستانه با توجه به مقادیر ماتریس  $G$  انتخاب شده بعارتی این مقدار آستانه وابسته به مقادیر ماتریس  $G$  مربوط به هر کلاس است. در جدول ۳-۵-ب که نتایج مربوط به انتخاب مقدار آستانه میانه می‌باشد، الگوریتم پیشنهادی قادر به تشخیص کلاس سوم و ششم نمی‌باشد بطوریکه داده‌های ورودی مربوط به این کلاس‌ها را به ترتیب بعنوان کلاس دوم و چهارم کلاس‌بندی می‌کند. عدم توانایی سیستم پیشنهادی در شناسایی کلاس سوم و ششم مربوط عدم ایجاد ماتریس  $H$  یکتا توسط این مقدار آستانه و بطبع آن عدم ایجاد بردار ویژگی یکتا است. شناسایی مابقی کلاس‌ها جزء کلاس اول نیز در حد متوسطی می‌باشد. دو نمونه از ماتریس  $H$  مربوط به کلاس دوم و سوم در شکل ۵-۵ به جهت مشاهده شباهت ماتریس  $H$  آنها آورده شده است. چون ماتریس  $H$  مربوطه به هر کلاس با این مقدار آستانه بسیار شبیه به هم می‌باشند، دلیل عدم توانایی را می‌توان در کمبودن تعداد داده آموزشی جهت آموزش شبکه عصبی نیز دانست.

جدول ۳-۵- میزان شناسایی کلاس‌ها با تغییر مقدار آستانه (الف) متوسط (ب) میانه (پ) ۰.۰۵

کلاس هفتم	کلاس ششم	کلاس پنجم	کلاس چهارم	کلاس سوم	کلاس دوم	کلاس اول	کلاس تشخیصی کلاس ورودی
٪۰.۶۷	۰	۰	۰	۰	۰	٪۹۹.۳۳	کلاس اول
٪۰.۳۳	۰	۰	۰	٪۴.۳۳	٪۹۳.۶۷	۰	کلاس دوم
٪۳.۶۷	۰	۰	۰	٪۹۴	٪۰.۶۷	۰	کلاس سوم
۰	٪۰.۳۳	۰	٪۹۹	۰	٪۰.۶۷	۰	کلاس چهارم
٪۱	٪۰.۳۳	٪۹۴.۶۷	۰	۰	٪۰.۶۷	٪۰.۳۳	کلاس پنجم
۰	٪۱۰۰	۰	۰	۰	۰	۰	کلاس ششم
٪۹۹.۶	۰	۰	۰	۰	٪۰.۴	۰	کلاس هفتم

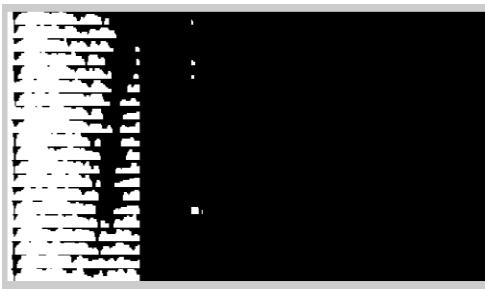
(الف)

کلاس هفتم	کلاس ششم	کلاس پنجم	کلاس چهارم	کلاس سوم	کلاس دوم	کلاس اول	کلاس تشخیصی کلاس ورودی
۰	۰	۰	۰	۰	۰	٪۱۰۰	کلاس اول
۰	۰	۰.۳۳	٪۱۳.۳۳	۲.۳۳	٪۷۹	٪۲۳	کلاس دوم
٪۴.۳۳	۰	٪۴.۳۳	٪۲۲.۶۷	۱	٪۶۱	٪۱.۳۳	کلاس سوم
٪۰.۶۷	۰	٪۱.۶۷	٪۸۳.۳۳	۰	٪۴	٪۸.۶۷	کلاس چهارم
٪۹.۶۷	٪۰.۳۳	٪۶۲.۳۳	٪۱۸.۶۷	۰	٪۰.۶۷	٪۵.۶۷	کلاس پنجم
۰	۰	٪۷.۶۷	٪۹۰	۰	۰	٪۲.۳۳	کلاس ششم
٪۶۸	۲۴	٪۰.۲۸	۰	۰	۰	٪۵.۲	کلاس هفتم

(ب)

کلاس هفتم	کلاس ششم	کلاس پنجم	کلاس چهارم	کلاس سوم	کلاس دوم	کلاس اول	کلاس تشخیصی کلاس ورودی
٪۶۴.۶۷	۰	۰	۰	۰	۰	٪۳۵.۳۳	کلاس اول
٪۱۹.۳۳	۰	۰	۰	٪۸.۶۷	٪۶۸.۶۷	۰	کلاس دوم
۰	۰	٪۰.۳۳	۰	٪۷۲	٪۱۱.۳۳	۰	کلاس سوم
۰	۰	٪۰.۳۳	٪۹۶.۶۷	۰	٪۰.۶۷	۰	کلاس چهارم
۰	۰	٪۱۰۰	۰	۰	۰	۰	کلاس پنجم
۰	٪۱۰۰	۰	۰	۰	۰	۰	کلاس ششم
٪۱۰۰	۰	۰	۰	۰	٪۰.۴	۰	کلاس هفتم

(پ)



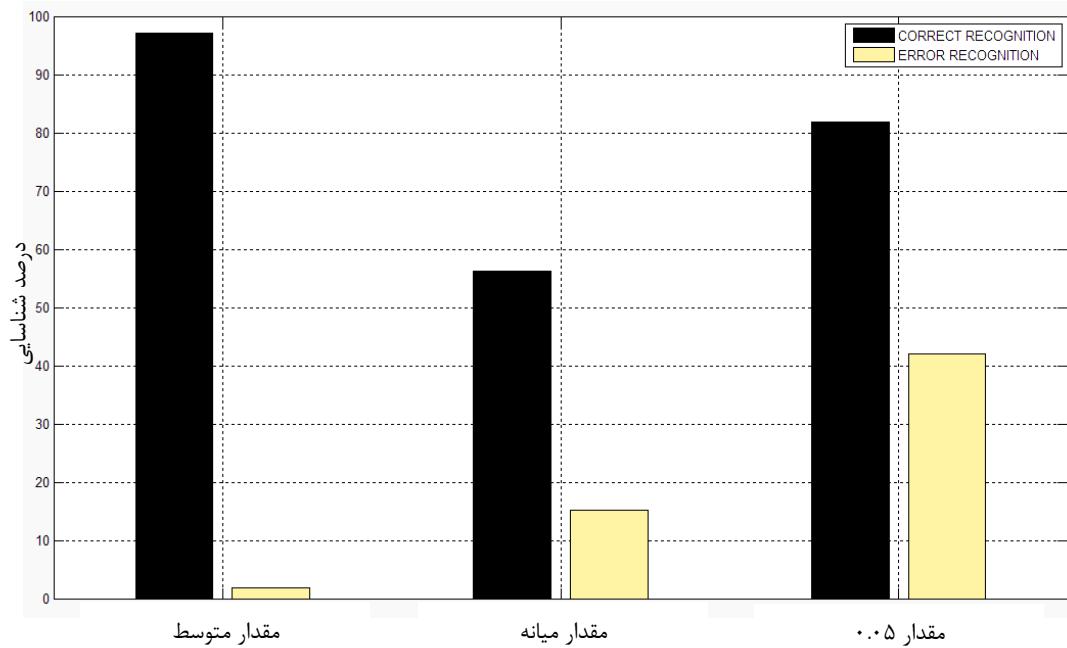
(الف)



(ب)

شکل ۵-۵- ماتریس H حاصل از کاربرد مقدار میانه برای باینری کردن ماتریس G (الف) کلاس دوم (ب) کلاس سوم

با میانگین‌گیری از تمام نرخ‌ها، نرخ شناسایی متوسط صحیح  $56.23\%$  و نرخ شناسایی متوسط نادرست  $41.97\%$  برای الگوریتم پیشنهادی با مقدار آستانه میانه حاصل می‌گردد. در جدول ۵-۳-پ نتایج با استفاده از مقدار آستانه  $0.05$  بدست آمده است. تفاوت این مقدار با دو مقدار قبلی - که بر اساس محتوای عددی ماتریس G تغییر می‌کردند - در ثابت بودن این مقدار با توجه به تغییر مقادیر ماتریس G می‌باشد. میزان شناسایی کلاس‌های چهارم، پنجم، ششم و هفتم ب این مقدار آستانه در حد بالای قرار دارد. میزان شناسایی کلاس‌های دوم و سوم نیز در حد متوسطی می‌باشند. اما نرخ تشخیص کلاس اول بسیار بد بوده بطوریکه این کلاس را بیشتر بعنوان کلاس هفتم تشخیص داده است. برای دانستن میزان تشخیص صحیح و تشخیص نادرست الگوریتم پیشنهاد شده با این مقدار، از نتایج متوسط‌گیری نموده، مقدار  $81.81\%$  تشخیص صحیح و مقدار تشخیص نادرست  $15.1\%$  محاسبه می‌گردد. میزان تشخیص کلی مقادیر ذکر شده از آستانه در شکل ۶-۵ به صورت نمودار آورده شده است. با انجام این آزمایش با توجه به مقادیر حاصل از تشخیص صحیح و نادرست ذکر شده در قسمت‌های الف و ب، به این نتیجه‌گیری می‌توان رسید که برای انتخاب مقدار آستانه، وابستگی مقدار آستانه به محتوای مقداری ماتریس G دابسته نیست، به معنای دیگر مقدار آستانه متغیر متنضم ایجاد ماتریس H و بطبع آن بردار ویژگی یکتا نمی‌باشد. از طرفی انتخاب مقدار آستانه ثابت (قسمت پ جدول ۵-۳) نیز با توجه به میزان شناسایی بسیار پایین ( $35.33\%$ ) کلاس اول و متوسط کلاس دوم ( $68.67\%$ ) و کلاس سوم ( $72\%$ ) نرخ شناسایی خوبی را برای کلاس‌ها ضمانت نمی‌کند. بنابراین نتیجه نهایی که از گفته‌های بالا می‌توان داشت اینست که انتخاب مقدار آستانه، یک فرایند تجربی است.



شکل ۵-۶- نمودار نرخ تشخیص صحیح و نادرست با استفاده از مقدار آستانه (الف) مقدار متوسط (ب) مقدار میانه (ج) مقدار ۰.۰۵

۳.۳.۵. مقایسه الگوریتم پیشنهادی با دو روش موجود در آخرین آزمایش انجام شده به ارزیابی کارایی الگوریتم پیشنهاد شده در مقایسه دو روش موجود فراکتال [۱۶] و متوسطگیری طیفی [۴] می‌پردازیم . در این آزمایش میزان شناسایی کلاس‌های مختلف را در حضور نویز با سیگنال به نویز های مختلف و در غیاب نویز با استفاده از روش پیشنهادی و دو روش دیگر بررسی می‌نماییم . این آزمایش شامل دو مقایسه است . مقایسه اول مقایسه کارایی روش پیشنهادی و دو روش دیگر در غیاب نویز و با سیگنال به نویزهای ۱۰ دسیبل و صفر دسیبل با هفت کلاس خروجی می‌باشد . مقایسه دوم با همان شرایط نویزی قبلی اما با پنج کلاس خروجی انجام می‌شود . این پنج کلاس خروجی شامل کلاس دوم تا ششم در مقایسه اول می‌باشند . نتایج این دو مقایسه را در جدول ۴-۵ و نمودار مربوطه نیز در شکل ۷-۵ آورده‌ایم .

جدول ۴-۵- مقایسه کارایی مجموع روش پیشنهادی با کارایی مجموع دو روش دیگر در شرایط نویز مختلف

روش	شرایط نویز	بدون نویز	سیگنال به نویز صفر دسیبل	سیگنال به نویز ۱۰ دسیبل	سیگنال به نویز ۱۰ دسیبل
روش پیشنهادی	%۹۷.۴۲	%۹۷.۱۸	%۷۸.۷	%۳۵.۵۹	%۲۵.۵
روش فراکتال	%۶۶.۶۷	%۴۱.۴۲	%۲۹	%۹۶.۲۶	%۷۶.۰۴
روش متوضط‌گیری طیفی	%۵۲.۸۵				

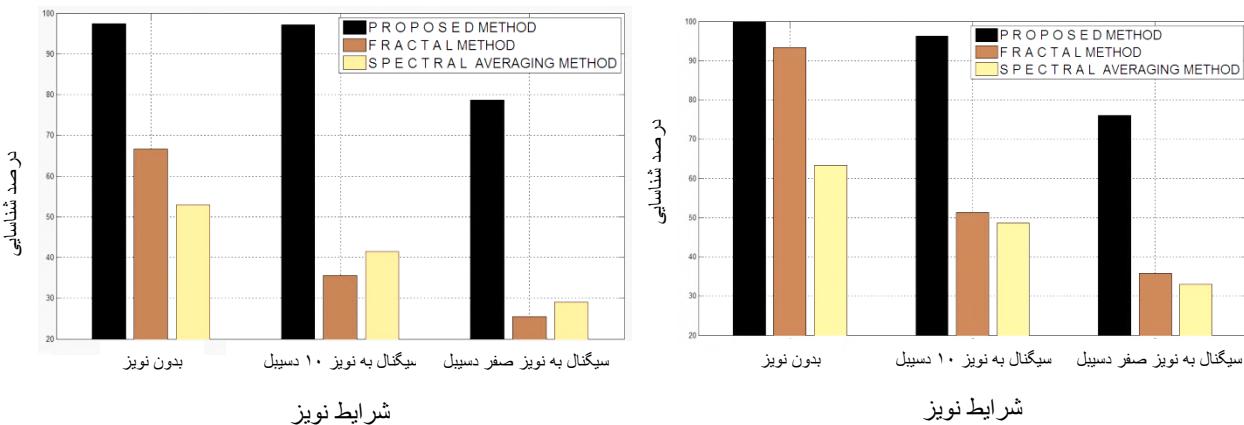
(الف) نتایج مربوط به مقایسه اول با هفت کلاس طبقه‌بندی

روش	شرایط نویز	بدون نویز	سیگنال به نویز صفر دسیبل	سیگنال به نویز ۱۰ دسیبل
روش پیشنهادی	%۱۰۰	%۹۳.۳۳	%۵۱.۲۳	%۹۶.۲۶
روش فراکتال	%۶۳.۳۳	%۹۳.۳۳	%۴۸.۵۹	%۳۵.۷۰
روش متوضط‌گیری طیفی	%۳۲.۹۷			

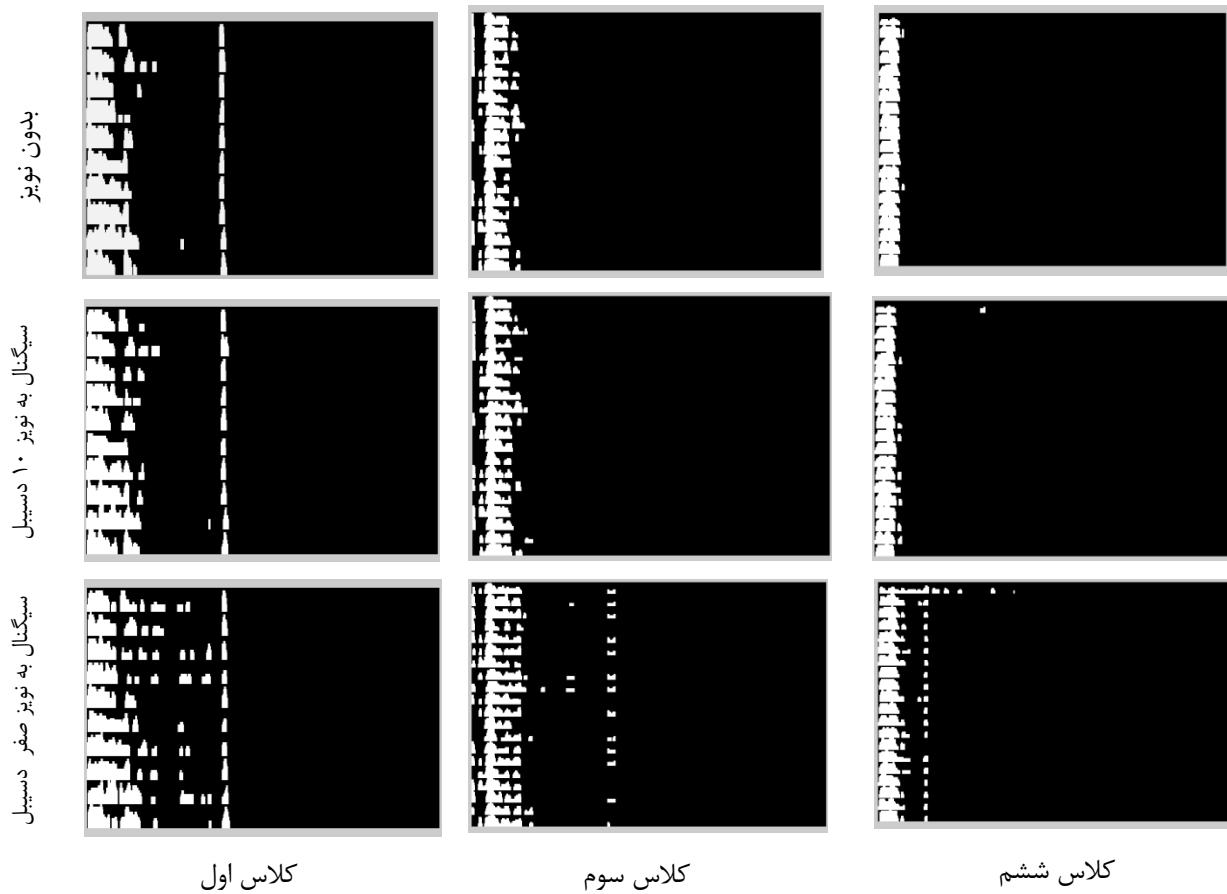
(ب) نتایج مربوط به مقایسه دوم با پنج کلاس طبقه‌بندی

همانگونه که از جدول ۴-۵ (الف) و (ب) قابل مشاهده می‌باشد ، روش پیشنهادی در شرایط بدون نویز تا سیگنال به نویز ۱۰ دسیبل از قابلیت بالای تشخیصی - بالای ۹۵٪ تشخیص صحیح - در هر دو مقایسه برخوردار است . اگرچه به میزان ۲۰٪ در سیگنال به نویز صفر دسیبل از کارایی آن در هر دو مقایسه کاسته می‌شود اما باز هم دارای عملکرد خوبی - حدود ۴۰٪ تا ۴۵٪ قابلیت شناسایی بیشتر - در مقایسه با دو روش دیگر در این شرایط نویزی بهره‌مند است . برای داشتن دیدگاه بهتری از نحوه عملکرد الگوریتم پیشنهادی ، ماتریس H سه کلاس با شرایط نویزی ذکر شده در شکل ۵-۸ نشان داده شده است . روش فراکتال در شرایط بدون نویز در طبقه‌بندی با هفت کلاس از قابلیت خوبی برخوردار است ولی کارایی آن در طبقه‌بندی با پنج کلاس حدود ۳۳٪ بهتر از کارایی آن در طبقه‌بندی هفت کلاسه می‌باشد . عملکرد روش فراکتال در طبقه‌بندی هفت کلاسه ۱۶٪ از قابلیت شناسایی همین روش در طبقه‌بندی پنج کلاسه با سیگنال به نویز ۱۰ دسیبل پایین‌تر می‌باشد . این روش در مقایسه دوم با سیگنال به نویز صفر دسیبل ، از کارایی بالاتری هم نسبت به همین روش در مقایسه

اول و هم نسبت به کارایی روش متوسط‌گیری در مقایسه دوم با همین شرایط نویزی برخوردار می‌باشد . روش متوسط‌گیری طیفی دارای تفاوت محسوس تشخیصی به اندازه ۷٪ تا ۱۱٪ در مقایسه دوم نسبت به مقایسه اول با شرایط سیگنال به نویز ۱۰ دسیبل تا بدون نویز می‌باشد . اما تفاوت محسوسی در شرایط سیگنال به نویز صفر دسیبل آن با کاهش تعداد کلاس‌ها وجود ندارد . از توصیفات بالا دو نتیجه‌گیری می‌توان داشت ، نتیجه اول اینکه روش پیشنهاد شده از قابلیت شناسایی بالایی برای قایق‌ها و دلفین‌ها در مقایسه با دو روش دیگر برخوردار است ، این را می‌توان با بررسی ستون اول هر دو مقایسه مشاهده کرد . عملکرد روش پیشنهادی با کاهش تعداد کلاس‌ها ۲.۵٪ افزایش یافته در صورتی که عملکرد روش فراکتال با ۲۷٪ بهبود شناسایی داشته و عملکرد روش متوسط‌گیری طیفی با افزایش کم ۱۱ درصدی به مقدار ۶۳.۳٪ تشخیص صحیح دست یافته است . نتیجه دومی که استنباط می‌شود ، قابلیت بالای عملکردی روش پیشنهادی در شرایط نویزی می‌باشد . بعنوان مثال اگر مقایسه دوم را که هر دو روش دیگر در آن دارای عملکرد بهتری هستند ، در نظر بگیریم ، با اعمال نویز با شرایط سیگنال به نویز ۱۰ دسیبل ، روش فراکتال با کاهش ۴۲٪ عملکرد به نرخ شناسایی صحیح ۵۲٪ و روش متوسط‌گیری طیفی با ۱۵٪ کاهش عملکرد به نرخ تشخیص صحیح ۴۸٪ می‌رسند یا به معنای دیگر تنها قادر به شناسایی صحیح نیمی از داده‌ها می‌باشند . در صورتی که الگوریتم پیشنهادی با ۴٪ کاهش کارایی بازهم دارای قابلیت عملکردی بالای ۹۰٪ می‌باشد .



شکل ۷-۵- نمودار نرخ شناسایی در شرایط نویزی مختلف با (الف) هفت کلاس طبقه‌بندی (ب) پنج کلاس طبقه‌بندی



شکل ۵-۸- ماتریس‌های  $H$  کلاس‌های اول ، سوم و ششم با شرایط نویزی مختلف

#### ۴.۵. نتیجه‌گیری

در این روشی ارائه شد که قادر بود سیگنال صوت زیرآب را دریافت کرده و کلاس مربوط به آن را تشخیص دهد. این الگوریتم که بر پایه تبدیل فوریه سریع کوتاه SFFT و تشکیل یک تصویر باینری با استفاده از جمع متوالی طیف‌های ناشی از بخش‌بندی سیگنال ورودی می‌باشد . ویژگی‌های جداساز را از این ماتریس باینری استخراج می‌نماییم و آن را برای کلاس‌بندی به یک کلاس‌بند عصبی می‌دهیم . مقایسه شبیه‌سازی الگوریتم پیشنهادی با شبیه‌سازی دو روش دیگر در شرایط متفاوت از سیگنال به نویز قابلیت بالای آنرا نشان داد . الگوریتم پیشنهادی در شرایط بدون نویز قابلیت تشخیص بیش از ۹۷٪ ، در شرایط سیگنال به نویز ۱۰ دسیبل قابلیت تشخیص بیش از ۹۶٪ و در شرایط سیگنال به نویز صفر دسیبل هم قابلیت تشخیص بیش از ۷۵٪ را در هر دو مقایسه از خود نشان داد . الگوریتم پیشنهادی دارای دو مزیت عمدی باشد . اولین مزیت آن اینست که در مقابل نویز بسیار

مقاوم است . دومین مزیت آن ، با تعداد ویژگی‌های کم - ۱۰ ویژگی - دارای عملکرد شناسایی بسیار بالای می‌باشد .

#### ۵.۵. پیشنهاد ادامه کار

با توجه به توضیحات ارائه شده در فصل‌های قبل موارد زیر به عنوان پیشنهاد ادامه کار مطرح می‌گردد :

- ارائه الگوریتمی برای محاسبه مقدار بهینه آستانه جهت ساخت ماتریس باینری  $H$
- اعمال عملیات پیش‌پردازشی مؤثرتر بر روی ماتریس  $H$  جهت کاهش بعد ماتریس
- استخراج ویژگی‌های مصون نسبت به نویز از ماتریس  $H$
- گسترش بانک داده مورد استفاده

٦-مراجع

- [1] R. J. Urick, “**Principles of underwater sound**”, 3rd editon, McGraw-Hill , New York,1983.
- [2] R.D.Collier , “Ship and platform noise, propeller noise. Handbook of acoustics”. M. J. Crocker, John Wiley & Sons.1998.
- [3] I.Dyer , “Ocean Ambient Noise. Handbook of Acoustics”. M. J. Crocker, John Wiley & Sons.1998.
- [4] W.S.Fillho , J.M.de Seixas , L.P.Caloba, “Averaging Spectra to Improve the Classification of the Noise Radiated by Ships Using Neural Networks” , 1522-4899 , IEEE 2000.
- [5] D. Damazio, W. Soares-Filho, and J. Seixas, “Efeito da estimacao do ruido ambiente na classificacao com redes neurais do ruido irradiado por navios”, In XI11 Congress0 Brasileiro de Automatica, 2000.
- [6] A. Oppenheim and R. Schafer, “**Digital signal processing**”,Prentice Hall, Englewood Cliffs, NJ, 1975.
- [7] K. Shammughan and A. Breipohl. “**Random Signals: Detection,Estimation, and Data Analysis**”, John Wiley & Sons,1988.
- [8] W. A. Struzinski and E. D. Lowe. “A performance comparison of four noise background normalization schemes proposed for signal detection systems”, jasa, 76(6):1 738-1742, 1984.
- [9] M. Farrokhrooz, M. Karimi, A. Rafiei, “A new method for spred value estimation in multi-spread PNN and its application in ship noise classification” , 1-4244-0779-6,IEEE 2007.
- [10] Qi Hu Li, and Wei Wei “An application of expert system in recognition of radiated noise of underwater targets”. Proc.OCEANS’95 Conf., vol. 1, pp. 404-408,1995.

- [11] J. M. Seixas, D.O. Damazio, PS.R. Diniz, W Soares-Fillho, "Wavelet transform as preprocessing method for neural network classification of passive sonar signals", 0-7803-7057-0, IEEE 2001.
- [12] S. Haykin, "Neural Networks: A Comprehensive Foundation", second edition, Prentice-Hall, 1999.
- [13] L.A. Pflug et al. "Variability in Higher Order Statistics of Measured Swallow-Water Shipping Noise". IEEE Signal Processing Workshop on Higher-Order Statistics, pp. 400-404, 1997.
- [14] R.O. Nielsen, "Sonar Signal Processing", Artech, 1991.
- [15] C.S. Bums, R.A. Gopinath, H. Guo, "Introduction to Wavelets and Wavelet Transforms", Prentice-Hall, 1998.
- [16] S.Yang , Z.Li , Xinlong Wang , "Ship recognition via its radiated sound: The fractal based approaches" , 172 J. Acoust. Soc. Am. 112 (1), July 2002.
- [17] M. S. Keshner, "1/f noise", Proc. IEEE 70, 212–218 ,1982.
- [18] B. D. Ripley, "Pattern Recognition and Neural Networks", Cambridge University Press, Cambridge, 1996.
- [19] B. B. Mandelbrot and H. W. Van Ness, "Fractional Brownian motions, fractional noises and applications", SIAM Rev. 10, 422–436 ,1968.
- [20] D. R. Carmichael, L. M. Linnett, S. J. Clarke, and B. R. Calder, "Seabed classification through multifractal analysis of sidescan sonar imagery", IEE Proc. Radar, Sonar Navig. 143, 140–148 ,1996.
- [21] S. Yang, Z. S. Li, and X. L. Wang, "Vessel radiated noise recognition with fractal features" , Electron. Lett. 36, 923–924 ,2000.
- [22] P. Maragos and Fang-Kuo Sun, "Measuring the fractal dimension of signals: Morphological covers and iterative optimization", IEEE Trans. Signal Process. 41, 108–121 ,1993.
- [23] G. Wornell, "Signal Processing with Fractals: A Wavelet-Based Approach" ,Prentice-Hall, Upper Saddle River, NJ, 1996, pp. 1–111.
- [24] C.Kang, X.Zhang , "A Fusion Algorithm of Multiple Classifiers for recognition of Ships Radiated–Noises Based on Many-Person Decision-Makings Theory" , 0-7695-2874-0/07,IEEE 2007.

- [25] Li D.F, "Fuzzy Multi-objective Many-Person Decision Makings and Games", National Defense Industry Press,Beijing, 2003.
- [26] Kang,C.Y, Zhang,X.H,et al, "Underwater Acoustic Targets Classification Using Welch Spectrum Estimation and Neural Networks", Advances in Neural Networks ISNN2004.Springer, 2004, pp. 930-935
- [27] Zhang,X.H, Kang,C.Y,Xia,Z.J, "Recognition of Radiated Noises of Ships Using Auditory Features and Support Vector Machines", Advances in Neural Networks ISNN2005, Springer, 2005, pp. 387-392.
- [28] Lu Z.B, "Feature Analysis of Radiated Noises of Ships based on Auditory Model", Dalian Navy Academy Masteral Dissertation, 2004.
- [29] G.Z.SHI, J.C.HU , "SHIP NOISE DEMODULATION LINE SPECTRUM FUSION FEATURE EXTRACTION BASED ON THE WAVELET PACKET" , 1-4244-1066-5, IEEE 2007.
- [30] SHI Guangzhi, HU Junchuan, "Extraction and fusion of frecquency domain features from ship radiated-noise based on wavelet and 1½ dimensional spectrum", Technical Acoustics, Vol. 23, No. 1, pp. 5-8, 2004.
- [31] W.Guoqing, L.Jing, "Ship radiated-noise recognition(III)—feature extraction of double frequency spectrum and average power spectrum and their pattern plates", ACTA ACUSTICA, 1999, Vol.24, No. 2, pp. 191-196.
- [32] F.zuyun, "Information Theory——Basic Theory and Application", Beijing: Publishing House of Electronics Industry, pp. 20-33, 2001.
- [33] S.Guangzhi, H.Junchuan, "Theoretical analysis of the ship noise demodulation spectrum harmonic clan feature", ACTA ACUSTICA, Vol. 32, No. 1, pp. 19-25,Jan.2007.
- [34] D.Ross, "Mechanics of underwaternoise", Penisula , 1988.
- [35] Matlab Software Help
- [36] Shalkoff, R, J. (1997). Artifical Neural Networks. McGraw-Hill.

[۳۷] منهاج ، محمد باقر (۱۳۸۱) . مبانی شبکه های عصبی . دانشگاه صنعتی امیر کبیر

## Abstract

Underwater radiated noise of ships in the sea has some information about their machineries . The information can be used to recognize them . It is a difficult task to recognize ships by underwater radiated sound due to there are a lot of changes in sea`s environment , special characteristics of sound transmission channels in underwater and interference-wave in sea`s environment. One of the most important approach in ships recognition by radiated sound underwater is extracting individual features from the underwater sound of ships which is an attracting subject for researchers.

The main target of this thesis is to suggest an algorithm for ships recognition by their underwater radiated sound. In this thesis we use adding spectrums respectively that are obtained from segmentation of input signal and form a binary image to extract features. Extracted features are given to the input of neural network . Then the kind of ship will be determined. Different experiments have been done on a database of sound ships. This database is consist of the sound of 20 files of heavy ship, 10 files of boat, 60 files of average ship, 20 files of submarine,12 files of dolphin. The correct recognition rate in 7 classes is % 97.18 with SNR=10dB and it is %96.26 in 5 classes with the same SNR .



Shahrood University of Technology  
Faculty of Electrical and Robotic Engineering

**Ships Recognition  
by using  
Underwater Radiated Sound**

By  
**Alireza Varedan**

Under Supervision of  
**Dr. Hossien Marvi**  
Consultant  
**Dr. Hadi Amiri**

September 2010