

صلى الله عليه وآله



دانشکده مهندسی برق و رباتیک

رشته برق

گرایش مخابرات - سیستم

پایان نامه کارشناسی ارشد

تشخیص نوع هواپیما با استفاده از صدای انتشاری موتور آن مبتنی بر شبکه

عصبی

نگارنده:

حنانه هادیان امرئی

استاد راهنما:

دکتر حسین مروی

شهریور ماه ۱۳۹۷

شماره ۱۵۸۹
تاریخ: ۸۷/۶/۷

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای حنا هادیان امرئی با شماره

دانشجویی ۹۴۱۸۸۳۴ رشته مهندسی برق- مخابرات گرایش سیستم تحت عنوان: تشخیص نوع هواپیما با

استفاده از صدای انتشاری موتور آن مبتنی بر شبکه عصبی که در تاریخ ۱۳۹۷/۰۶/۰۷ با حضور هیأت محترم

داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می گردد:

قبول (با درجه: <u>خیلی خوب</u>)	☒	مردود	☐
نوع تحقیق:	☒ نظری	☐ عملی	

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	مهندس مراد	دانشیار	
۲- استاد راهنمای دوم	_____	_____	_____
۳- استاد مشاور	_____	_____	_____
۴- نماینده تحصیلات تکمیلی	ولی اسحاقی	استادیار	
۵- استاد ممتحن اول	ایمن زاده سرمد	استادیار	
۶- استاد ممتحن دوم	هادی گراملو	استادیار	



تبصره: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می تواند از پایان نامه خود دفاع نماید (دفاع مجدد نباید زودتر از ۴ ماه برگزار شود).

تقدیر و شکر

سپاس خدای را که سخنوان، در ستودن او بماند و شمارندگان، شمردن نعمت های او ندانند و کوشندگان، حق او را گزارش ندهند. و سلام و دود بر محمد و خاندان پاک او، طاهران معصوم، هم آنان که وجودمان و مدار وجودشان است؛ و نفرین پیوسته بر دشمنان رستخیز، از آنجایی که تجلیل از معلم، سپاس از انسانی است که هدف و غایت آفرینش را تائید می کند و سلامت امانت های را که به دستش سپرده اند، تضمین؛ بر حسب وظیفه و از باب "من لم یسکر المنعم من المخلوقین لم یسکر الله عزوجل" از پدر و مادر عزیزم این دو معلم بزرگوارم که همواره بر کوتاهی و درستی من، قلم عفو کشیده و گریانه از کنار غفلت هایم گذشته اند و در تمام عرصه های زندگی یار و یاور بی چشم داشت برای من بوده اند؛ از استاد با کمالات و شایسته؛ جناب آقای دکتر حسین مروی که در کمال سعه صدر، با حسن خلق و فروتنی، از پیچ گلی در این عرصه بر من دریغ ننمودند و زحمت راهبانی این پایان نامه را بر عهده گرفتند کمال شکر و قدردانی را دارم. باشد که این خردترین، بخشی از زحمات آنان را سپاس گوید.

تعهد نامه

اینجانب **حنانه هادیان امرئی** دانشجوی دوره کارشناسی ارشد رشته **مهندسی برق گرایش مخابرات - سیستم**

دانشکده **مهندسی برق و رباتیک** دانشگاه صنعتی شاهرود نویسنده پایان نامه تشخیص نوع هواپیما با استفاده از

صدای انتشاری موتور آن مبتنی بر شبکه عصبی تحت راهنمایی آقای دکتر حسین مروی متعهد می شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاقی انسانی رعایت شده است .

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد.
- این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

اطلاعات مربوط به حرکت هواپیما معمولاً با رادار یا سنسورهای الکترونیکی جمع آوری می‌شوند، اما ممکن است این اطلاعات به علت عدم وجود میدان دید غیرسودمند باشند. تشخیص و شناسایی هدف توسط سیگنال‌های صوتی در بعضی موارد به علت موقعیت جغرافیایی، مقرون به صرفه بودن، استفاده در مسافت‌های نزدیک، مقاومت در برابر نویز حائز اهمیت می‌باشد. به همین خاطر روشی برای شناسایی هدف که کمتر توسط شرایط مسیر دید مختل می‌شود، مورد استفاده قرار می‌گیرد. این روش استفاده از صدای موتور هواپیما می‌باشد که در این پایان‌نامه مورد تحلیل قرار گرفته است. سیگنال‌های صوتی دریافتی از میکروفون به عنوان ورودی این الگوریتم در نظر گرفته می‌شود و به منظور استخراج ویژگی از انرژی تبدیل موجک، ضرایب کپستروم فرکانس مل (MFCC)، ضرایب کپستروم حقیقی، ضرایب پیشگوی خطی (LPC) و فرکانس طیفی خط (LSF) استفاده شده است. سپس طبقه‌بندی سیگنال‌های صوتی هواپیما برای چهار کلاس مختلف از داده‌های صوتی توسط طبقه بند شبکه عصبی مصنوعی انجام می‌گیرد. پس از آن برای ارزیابی عملکرد سیستم تشخیص، نویز با نسبت سیگنال به نویز^۱های مختلف به سیگنال اضافه شده و نتایج حاصل از آن را با یکدیگر مقایسه شده است. در نهایت روشی برای بهبود عملکرد سیستم معرفی شده که از تبدیل موجک برای حذف نویز و از ترکیب LSF و ضرایب کپستروم حقیقی به عنوان روش استخراج ویژگی استفاده می‌کند و نرخ طبقه‌بندی داده را به ۹۳/۱۱٪ و میزان خطا را به ۰/۰۴۵۱ می‌رساند.

کلید واژه‌ها: تشخیص نوع هواپیما، تبدیل موجک، ضرایب کپستروم فرکانس مل، ضرایب پیشگوی خطی، ضرایب کپستروم حقیقی، و فرکانس طیفی خط، شبکه عصبی مصنوعی.

^۱Signal-to-Noise Ratio (SNR)

فهرست مطالب

فصل اول: مقدمه.....	۱
۱.۱) پیشگفتار.....	۲
۲.۱) تشخیص و طبقه‌بندی انواع هواپیما.....	۳
۳.۱) هدف پایان نامه.....	۳
۴.۱) ساختار کلی پایان نامه.....	۴
فصل دوم: مروری بر کارهای گذشته در تشخیص نوع هواپیما.....	۵
۱.۲) پیشگفتار.....	۶
۲.۲) چارچوب کلی تشخیص نوع هواپیما.....	۶
۳.۲) پیشینه و سوابق مرتبط با تشخیص و طبقه‌بندی انواع هواپیما.....	۷
۴.۲) جمع‌بندی.....	۲۳
فصل سوم: مبانی نظری.....	۲۵
۱.۳) پیشگفتار.....	۲۶
۲.۳) جمع‌آوری داده و ضبط صدا.....	۲۶
۱.۲.۳) سخت‌افزار ASAD.....	۲۶
۲.۲.۳) سنسورهای پسیو.....	۲۸

۳.۳	پیش پردازش.....	۲۹
۴.۳	اعمال پنجره.....	۲۹
۵.۳	استخراج ویژگی.....	۳۰
۱.۵.۳	تبدیل موجک.....	۳۱
۲.۵.۳	ضرایب پیشگویی خطی (LPC).....	۳۳
۳.۵.۳	فرکانس طیفی خطی (LSF).....	۳۴
۴.۵.۳	ضرایب کپستروم فرکانس مل (MFCC).....	۳۵
۵.۵.۳	ضرایب کپستروم.....	۳۸
۶.۳	تکنیک طبقه‌بندی.....	۳۸
۱.۶.۳	شبکه عصبی مصنوعی جلو رونده (FFAN).....	۳۹
۲.۶.۳	تابع فعالسازی.....	۴۱
۷.۳	جمع‌بندی.....	۴۲
	فصل چهارم: روش پیشنهادی.....	۴۳
۱.۴	پیشگفتار.....	۴۴
۲.۴	روش تشخیص و طبقه‌بندی انواع هواپیما.....	۴۴
۳.۴	پایگاه داده مورد استفاده در این پایان‌نامه.....	۴۶
۴.۴	پیش پردازش.....	۴۸

۴۹	شیه سازی	۵.۴
۴۹	LPC ویژگی استخراج از روش تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی LPC	۱.۵.۴
۵۰	MFCC ویژگی استخراج از روش تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی MFCC	۲.۵.۴
۵۰	موجک	۳.۵.۴
۵۲	LSF ویژگی استخراج از روش تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی LSF	۴.۵.۴
۵۲	Cepstrum	۵.۵.۴
۵۳	اضافه کردن نویز به سیگنال و بررسی عملکرد آن	۶.۴
۵۳	نتایج شبیه سازی برای بهبود عملکرد سیستم	۷.۴
۵۴	جمع بندی	۸.۴
۵۵	فصل پنجم: نتایج و پیشنهادات	
۵۶	پیشگفتار	۱.۵
۵۶	نتایج شبیه سازی	۲.۵
۵۶	LPC ویژگی استخراج از روش تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی LPC	۱.۲.۵
۵۸	MFCC ویژگی استخراج از روش تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی MFCC	۲.۲.۵
۵۹	موجک	۳.۲.۵

حالت اول: نتایج حاصل از روش انرژی تبدیل موجک در ۴ سطح تجزیه با موجک‌های HAAR.	۵۹
db2 و db10.....	
حالت دوم: نتایج حاصل از روش انرژی تبدیل موجک با موجک db10 در سطوح تجزیه مختلف...۶۰	
۴.۲.۵) آزمایش چهارم نتایج حاصل از روش استخراج ویژگی LSF.....	۶۲
۵.۲.۵) آزمایش پنجم: نتایج حاصل از روش استخراج Real Cepstrum.....	۶۳
۳.۵) اضافه کردن نویز به سیگنال و بررسی عملکرد آن.....	۶۵
۱.۳.۵) آزمایش اول: تأثیر افزودن نویز در روش استخراج ویژگی LPC با P=10.....	۶۵
۲.۳.۵) آزمایش دوم: تأثیر افزودن نویز در روش استخراج ویژگی LPC با P=16.....	۶۶
۳.۳.۵) آزمایش سوم: تأثیر افزودن نویز در روش استخراج ویژگی MFCC.....	۶۷
۴.۳.۵) آزمایش چهارم: تأثیر افزودن نویز در روش استخراج ویژگی Real Cepstrum.....	۶۸
۵.۳.۵) آزمایش پنجم: تأثیر افزودن نویز در روش استخراج ویژگی LSF.....	۷۰
۶.۳.۵) آزمایش ششم: تأثیر افزودن نویز در روش استخراج ویژگی از انرژی تبدیل موجک در ۴ سطح تجزیه.....	۷۱
۷.۳.۵) آزمایش هفتم: تأثیر افزودن نویز در روش استخراج ویژگی از انرژی تبدیل موجک و با استفاده از موجک db10.....	۷۲
۴.۵) نتایج شبیه سازی برای بهبود عملکرد سیستم.....	۷۴
۵.۵) نتیجه گیری کلی.....	۷۵

۶.۵) مقایسه با کارهای گذشته..... ۷۸

۷.۵) پیشنهادات برای کارهای آینده..... ۷۹

مراجع ۸۰

فهرست شکل‌ها

- شکل (۱-۲): دیاگرام سیستم تشخیص ویژگی صوتی هدف..... ۶
- شکل (۲-۲): مقایسه عملکرد سه مدل طبقه‌بندی براساس ویژگی LSP..... ۹
- شکل (۳-۲): روند الگوریتم تشخیص بالگرد..... ۱۴
- شکل (۴-۲): روند الگوریتم شناسایی نوع بالگرد..... ۱۵
- شکل (۵-۲): سیگنال صوتی برخاستن هواپیمای جت..... ۱۷
- شکل (۶-۲): سیگنال صوتی برخاستن هواپیمای تک موتوره..... ۱۷
- شکل (۷-۲): اندازه گیری رابطه مقدار ماکزیمم..... ۱۷
- شکل (۸-۲): طبقه بندی درخت باینری..... ۱۸
- شکل (۱-۳): شماتیکی از سیستم تشخیص ارتعاش هوا (ASAD)..... ۲۷
- شکل (۲-۳): تصویر سیستم تشخیص ارتعاش هوا (ASAD)..... ۲۷
- شکل (۳-۳): شماتیکی از میکروفون خوشه ای که شامل ۶۴ میکروفون است..... ۲۸
- شکل (۴-۳): بلوک دیاگرام برای استخراج ویژگی..... ۳۰
- شکل (۵-۳): اجرای تبدیل موجک و معکوس آن توسط فیلتر کاسکاد..... ۳۲
- شکل (۶-۳): سنتز صوتی تولید شده توسط مدل LPC..... ۳۴
- شکل (۷-۳): دیاگرام مشتقات MFCC..... ۳۶
- شکل (۸-۳): سیستم طبقه بندی الگو..... ۳۹

- شکل (۳-۹): FFANN چند لایه..... ۴۰
- شکل (۳-۱۰): نرون‌های مدل شده..... ۴۰
- شکل (۳-۱۱): ساده‌ترین حالت شبکه عصبی جلو رونده..... ۴۱
- شکل (۳-۱۲): تابع فعالسازی sigmoid..... ۴۲
- شکل (۳-۱۳): تابع فعالسازی خطی..... ۴۲
- شکل (۴-۱): بلوک دیاگرام روش پیشنهادی..... ۴۶
- شکل (۴-۲): سیگنال اصلی..... ۴۷
- شکل (۴-۳): کپستروم سیگنال اصلی..... ۴۷
- شکل (۴-۴): سیگنال اصلی پس از پیش پردازش..... ۴۸
- شکل (۴-۵): اعمال پنجره همینگ روی سیگنال فریم شده..... ۴۹
- شکل (۵-۱): مقایسه نرخ طبقه بندی داده‌ها در ضرایب p مختلف..... ۵۸
- شکل (۵-۲): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب LPC..... ۵۸
- شکل (۵-۳): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب LSF..... ۶۳
- شکل (۵-۴): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب Real Cepstrum..... ۶۴
- شکل (۵-۵): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی Real Cepstrum با نویز ۳ dB..... ۶۹

شکل (۵-۶): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی Real Cepstrum با

نویز ۹ dB..... ۶۹

شکل (۵-۷): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی LSF با نویز

۳dB..... ۶۹

شکل (۵-۸): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی LSF با نویز

۹dB..... ۷۱

شکل (۵-۹): مقایسه نتایج روش پیشنهادی و LPC..... ۷۱

شکل (۵-۱۰): مقایسه نتایج روش پیشنهادی و LSF و MFCC..... ۷۱

شکل (۵-۱۱): مقایسه نتایج روش پیشنهادی و انرژی تبدیل موجک با موجک‌های مختلف..... ۷۶

شکل (۵-۱۲): مقایسه نتایج روش پیشنهادی و انرژی تبدیل موجک با سطوح تجزیه مختلف..... ۷۶

شکل (۵-۱۳): روش پیشنهادی..... ۷۷

شکل (۵-۱۴): مرجع [۷]..... ۷۸

شکل (۵-۱۵): مرجع [۱۳]..... ۷۹

فهرست جداول

- جدول (۱-۲): عملکرد ویژگی‌های مختلف در طبقه‌بندی..... ۸
- جدول (۲-۲): تشخیص صحیح با استفاده از سیگنال حذف نویز شده..... ۸
- جدول (۳-۲): تشخیص صحیح با استفاده از داده‌های نویزی و تمیز برای آموزش..... ۹
- جدول (۴-۲): نتایج طبقه‌بندی..... ۱۱
- جدول (۵-۲): عملکرد LPC..... ۱۲
- جدول (۶-۲): نتایج براساس سیگنال حذف نویز شده..... ۱۲
- جدول (۷-۲): انتخاب بهترین روش موجک ۱۳
- جدول (۸-۲): تابع هدف خروجی برای ۸ هلی کوپتر..... ۲۰
- جدول (۹-۲): درصد طبقه‌بندی صحیح ۲۱
- جدول (۱۰-۲): نتایج طبقه‌بندی با استفاده از سیگنال‌های تمیز..... ۲۱
- جدول (۱۱-۲): نتایج طبقه‌بندی با استفاده از سیگنال‌های تمیز و نویزی در آموزش..... ۲۲
- جدول (۱-۵): نتایج طبقه‌بندی با استفاده از ضرایب LPC..... ۵۷
- جدول (۲-۵): نتایج طبقه‌بندی با استفاده از MFCC..... ۵۹
- جدول (۳-۵): نتایج طبقه‌بندی با استفاده از انرژی تبدیل موجک (حالت اول)..... ۶۰
- جدول (۴-۵): نتایج طبقه‌بندی با استفاده از انرژی تبدیل موجک (حالت دوم)..... ۶۱
- جدول (۵-۵): نتایج طبقه‌بندی با استفاده از LSF..... ۶۲

- جدول (۵-۶): نتایج طبقه بندی با استفاده از Real Cepstrum ۶۴
- جدول (۵-۷): نتایج طبقه بندی سیگنال نویزی با استفاده از LPC , $P=10$ ۶۶
- جدول (۵-۸): نتایج طبقه بندی سیگنال نویزی با استفاده از LPC , $P=10$ ۶۷
- جدول (۵-۹): نتایج طبقه بندی سیگنال نویزی با استفاده از MFCC ۶۸
- جدول (۵-۱۰): نتایج طبقه بندی سیگنال نویزی با استفاده از Real Cepstrum ۶۹
- جدول (۵-۱۱): نتایج طبقه بندی سیگنال نویزی با استفاده از LSF ۷۰
- جدول (۵-۱۲): نتایج طبقه بندی سیگنال نویزی با استفاده از انرژی تبدیل موجک در ۴ سطح تجزیه ۷۲
- جدول (۵-۱۳): نتایج طبقه بندی سیگنال نویزی با استفاده از انرژی تبدیل موجک و db10 ۷۳
- جدول (۵-۱۴): نتایج طبقه بندی با استفاده از LSF+Real Cepstrum ۷۴

فصل اول: مقدمه

۱.۱) پیشگفتار

تکنولوژی شناسایی و تشخیص صوتی هواپیما به عنوان یک ابزار سنتی بخش مهمی از سیستم هشدار زود هنگام هواورد را تشکیل می‌دهد. هلی‌کوپتر که به وسیله‌ی یک یا چند روتور بزرگ افقی حرکت داده می‌شود بخاطر توانایی پرواز در ارتفاع کم توسط رادارهای معمولی غیر قابل شناسایی است. از این رو شناسایی بسیار مهم است. بطور معمول اطلاعات مربوط به حرکت هواپیما با رادار یا سنسورهای الکترونیکی جمع‌آوری می‌شوند، اما ممکن است این اطلاعات به علت عدم وجود میدان دید غیرسودمند باشند. تشخیص و شناسایی هدف توسط سیگنال‌های صوتی در بعضی موارد به علت موقعیت جغرافیایی، مقرون به صرفه بودن، استفاده در مسافت‌های نزدیک، مقاومت در برابر نویز حائز اهمیت می‌باشد. به همین خاطر روش دیگری برای شناسایی هدف که کمتر توسط شرایط مسیر دید مختل می‌شود مورد استفاده قرار می‌گیرد [۱]. این روش استفاده از صدای موتور هواپیما می‌باشد که سیگنال‌های صوتی دریافتی از میکروفون به عنوان ورودی این الگوریتم در نظر گرفته می‌شود و خروجی آنها نوع هواپیمای تشخیص داده شده می‌باشد. البته با توجه به نویز موجود در محیط ابتدا باید نویز از سیگنال اصلی تفکیک گردد. در این پایان‌نامه روش‌های استخراج ویژگی برای تشخیص و طبقه‌بندی انواع هواپیما مورد بررسی قرار گرفته و با اضافه کردن نویز با SNR های مختلف به سیگنال مقاومت آنها را در برابر نویز بررسی شده و با در نظر گرفتن نتایج بدست آمده روشی را ارائه شده که باعث بهبود عملکرد تشخیص خواهد شد.

۲.۱) تشخیص و طبقه‌بندی انواع هواپیما

به علت حساس بودن این موضوع در پردازش تصویر، پردازش صوت و با استفاده از رادار روش‌های متنوعی برای تشخیص نوع هواپیما ارائه شده است. ولی آن چیزی که اهمیت دارد استفاده از مطلوب-ترین روش‌ها با توجه به مشخصه‌های محیطی و شرایط سیگنال هدف است.

شناسایی صوتی چند مزیت دارد [۲]:

- ۱- روش‌های صوتی ساده هستند و تجهیزات آن ارزان قیمت و برای استفاده آسان هستند.
- ۲- صوت اجازه شناسایی هدف مورد علاقه (TOI^1) را در هر ارتفاعی، شامل اهداف زمینی با حرکت آهسته و اهداف ثابت را می‌دهد.
- ۳- سیستم‌های صوتی هیچ سیگنال ارتعاشی تولید نمی‌کند و توسط تجهیزات شناسایی امواج الکترومغناطیسی (EM^2) قابل شناسایی نیستند.
- ۴- تشخیص صوتی می‌تواند بصورت ترکیبی با رادار، سنسورهای الکترونیکی و یا مادون قرمز استفاده شود.

بنابراین ارائه روشی با مطلوب‌ترین پاسخ و سازگار با شرایط محیطی می‌تواند در این راه بسیار مؤثر باشد.

۳.۱) هدف پایان نامه

هدف این پایان‌نامه بررسی روش‌های موجود در استخراج ویژگی و مقایسه عملکرد آن‌ها در طبقه‌بندی است. همچنین تلاش شده است که با توجه به نتایج بدست آمده روش‌هایی برای تشخیص و

^۱ Targets of Interest

^۲ Electro Magnetic

طبقه‌بندی انواع هواپیما ارائه شود که مطلوب‌ترین نتایج را داشته باشند و میزان دقت طبقه‌بندی را افزایش و میزان خطا را تا حد مطلوبی کاهش دهند.

۴.۱) ساختار کلی پایان نامه

مطالب عنوان شده در این پایان نامه در قالب پنج فصل تدوین شده‌اند که به ترتیب زیر خلاصه می‌شوند.

۱- فصل اول: مقدمه

۲- فصل دوم: پیشینه تحقیق، که در این فصل به بررسی مهمترین تحقیقاتی که تا کنون برای تشخیص نوع هواپیما با استفاده از صدای انتشاری موتور آن انجام شده است، پرداخته می‌شود.

۳- فصل سوم: مبانی نظری، که در این فصل مطالب تئوری مربوط به تشخیص و طبقه‌بندی انواع هواپیما بررسی می‌شود.

۴- فصل چهارم: روش پیشنهادی، که در این فصل ساختار کلی روش تشخیص و طبقه‌بندی انواع هواپیما معرفی شده است. سپس روش‌های استخراج ویژگی‌های مورد استفاده در این روش معرفی شده و در نهایت با استفاده از طبقه‌بند شبکه عصبی مصنوعی به تشخیص و طبقه‌بندی انواع هواپیما خواهیم پرداخت.

۵- فصل پنجم: نتایج و پیشنهادات، که نتایج بدست‌آمده از روش پیشنهادی با هم مقایسه خواهند شد و به جمع‌بندی نتایج خواهیم پرداخت و در نهایت پیشنهاداتی برای ادامه و گسترش تحقیق در این زمینه ارائه خواهد شد.

فصل دوم: مروری بر کارهای گذشته در تشخیص


نوع هواپیما

۱.۲ پیشگفتار

مطالعه تحقیقات و پژوهش‌های پیشین انجام گرفته باعث افزایش آگاهی و دانش درخصوص کارهای انجام شده و آشنایی با روش‌های موجود و همچنین کمی‌ها و کاستی‌ها در این زمینه می‌شود و این امکان را می‌دهد تا بتوان در راستای پژوهش‌های انجام شده با ارائه روش‌های جدید نتایج قبلی را بهبود بخشید.

۲.۲ چارچوب کلی در تشخیص هواپیما

الگوریتم شناسایی ویژگی‌های صوتی هواپیمای هدف از الگوی شناسایی در شکل (۱-۲) پیروی میکند. که به قسمتهای (اکتساب داده، پیش پردازش، استخراج ویژگی و انتخاب تصمیم‌گیری) تقسیم می‌شود [۷].



شکل (۱-۲): دیاگرام سیستم تشخیص ویژگی صوتی هدف [۷].

در سیستم شناسایی ویژگی صوتی هواپیما، شناسایی هدف برای طراحی استخراج کننده ویژگی و طبقه بند بسیار حائز اهمیت است. همچنین استخراج ویژگی به علت تأثیر در کیفیت طبقه بندی و دارا بودن بیشترین اطلاعات موجود نسبت به دیگر قسمت‌های دیاگرام شکل (۱-۲) مهم‌ترین قسمت الگوی شناسایی سیستم است [۷].

۳.۲) پیشینه و سوابق مرتبط با تشخیص و طبقه‌بندی انواع هواپیما

در مرجع [۱] شبکه عصبی مصنوعی (ANN) در ترکیب با تکنیک‌های کدینگ براساس ضرایب پیشگوی خطی (LPC) ۲۰ نقطه‌ای، ضرایب انعکاسی (RC)، ضرایب کپستروم (CC) و جفت‌های طیفی خطی (LSP) برای تشخیص صدای هلی‌کوپتر به کار گرفته می‌شود. آموزش شبکه عصبی مصنوعی براساس صدای شبیه سازی شده از چهار هلی‌کوپتر مختلف S-67 , H500 , CH-47C , MI-HIND انواع صداها را در سطوح نویزی مختلف انجام شده است. پس از آن عملکرد شبکه عصبی با اضافه کردن نویز با نرخ سیگنال به نویز ۹، ۱۲ و ۱۸ دسی بل با حالت بدون نویز مقایسه شده است. جدول (۱-۲) نتایج عملکرد طبقه‌بند را در سطوح نویزی مختلف نشان می‌دهد. نتایج عملکرد LPC نشان می‌دهد که در حالت بدون نویز دقت تشخیص ۱۰۰٪ وجود دارد ولی هر چه سطح نویز بالاتر می‌رود به علت تخریب قله‌های طیفی توسط نویز و تار شدن قله‌ها و دره‌های طیفی نرخ تشخیص ضعیف‌تر می‌شود. نتایج عملکرد RC نشان می‌دهد که در حالت بدون نویز دقت تشخیص ۱۰۰٪ است و در حالت نویزی با توجه به محدوده دینامیکی $|K_i| < 1$ در ضرایب انعکاسی نویز افزایشی تغییرات کوچکی را در ضرایب انعکاسی ایجاد می‌کند که در نتیجه عملکرد آن رضایت‌بخش است.

ضرایب کپستروم (CC) به علت داشتن عملگر لگاریتم غیرخطی نویز سطح پایین بخشی از طیف صوتی را شامل می‌شود که همین عامل عملکرد طبقه‌بند را تضعیف می‌کند و دقت تشخیص را به ۹۸/۹٪ می‌رساند. نتایج عملکرد LSP تشخیص ۱۰۰٪ در حالت بدون نویز را نشان می‌دهد. پارامترهای LSP در خصوص قله طیفی فرکانس‌ها قابل تفسیر هستند. صفرهای چندجمله‌ای LSP روی دایره واحد قرار می‌گیرند و ریشه‌های متقارن و نامتقارن آن پراکنده هستند. همچنین نتایج این آزمایش نشان می‌دهد که بردارهای ویژگی LSP نسبت به دیگر بردارها در برابر نویز مقاوم‌تر است.

جدول (۲-۱): عملکرد ویژگی‌های مختلف در طبقه‌بندی [۱].

Parametric model used	Detection Results of	SNR			
		Clean	18dB	12dB	9dB
LPC	Helicopter	100%	71.5%	25%	9%
	Non-helicopter	95%	98.4%	99%	100%
	False Alarm	5%	1.6%	1%	0%
	Miss	0%	28.5%	75%	91%
RC	Helicopter	100%	80%	48%	33%
	Non-helicopter	96.2%	99%	100%	100%
	False Alarm	3.8%	1%	0%	0%
	Miss	0%	20%	52%	67%
CC	Helicopter	98.9%	84.7%	41.5%	10.3%
	Non-helicopter	100%	100%	100%	100%
	False Alarm	0%	0%	0%	0%
	Miss	1.1%	15.3%	58.5%	89.7%
LSP	Helicopter	100%	95%	60%	47%
	Non-helicopter	97%	99%	100%	99%
	False Alarm	3%	1%	0%	1%
	Miss	0%	5%	40%	53%

در ادامه سه روش برای بهبود عملکرد طبقه‌بند معرفی شده و نتایج حاصل از آن با نتایج اولیه مقایسه شده‌اند. این روش‌ها عبارتند از:

۱- حذف نویز سیگنال قبل از استخراج ویژگی، که توسط تبدیل موجک انجام می‌شود و برای اینکار با استفاده از موجک دابیشز db3 سیگنال را در سه سطح تجزیه می‌کند و برای انتخاب آستانه حذف نویز از آنتروپی تبدیل موجک استفاده می‌کند. جدول (۲-۲) برآورد طیفی سیگنال در قالب LSP - ۱۴ نقطه ای را ارائه می‌کند. همچنین طبقه بند ANN، ۱۴ نرون پنهان آموزش دیده دارد. نتایج تشخیص برای سیگنال‌های تست در مقایسه با نتایج قبلی حذف نویز نشده، بهتر است.

جدول (۲-۲): تشخیص صحیح با استفاده از سیگنال حذف نویز شده [۱].


Detection Results of	SNR			
	Clean	18 dB	12 dB	9 dB
Helicopter	100%	96.2%	70.3%	58.5%
Non-helicopter	95%	98%	99%	100%
False Alarm	5%	2%	1%	0%
Miss	0%	3.8%	29.7%	41.5%

۲- آموزش سیستم در محیطی شبیه به محیط آزمون، که برای کم کردن حساسیت ANN نسبت به تغییرات شکل طیفی از آموزش شبکه با استفاده از الگوی ایجاد شده با نویز پس زمینه استفاده می- کند. بدین منظور ANN روی ۱۴۰۰ فریم آموزش دیده است که ۷۰۰ فریم بدون نویز و ۷۰۰ فریم با نویز اضافه شده ۹ دسی بل هستند. جدول (۲-۳) نتایج طبقه‌بندی با استفاده از داده‌های نویزی و تمیز را نشان می‌دهد. با توجه به نتایج بدست آمده حتی در مورد نویز پس زمینه، عملکرد به طور قابل توجهی بهبود یافته است.

جدول (۲-۳): تشخیص صحیح با استفاده از داده‌های نویزی و تمیز برای آموزش.

Detection Results of	SNR			
	Clean	18 dB	12 dB	9 dB
Helicopter	100%	97.3%	81.2%	71.4%
Non-helicopter	98%	99%	100%	100%
False Alarm	2%	1%	0%	0%
Miss	0%	2.7%	18.8%	28.6%

شکل (۲-۲) مقایسه عملکرد طبقه‌بند مبتنی بر روش استخراج ویژگی LSP را در سه حالت آموزش توسط سیگنال بدون نویز، تکنیک حذف نویز توسط موجک و آموزش در محیط نویزی را ارائه می- دهد. نتایج شبیه سازی نشان می‌دهد که آموزش در محیط نویزی بهترین مقاومت در برابر نویز را داراست.



شکل (۲-۲): مقایسه عملکرد سه مدل طبقه‌بندی براساس ویژگی LSP [۱].

۳-تکنیک پس پردازش ساده مبتنی بر فیلتر میانگین گیر متحرک^۱، که یک روش ساده پس از پردازش برای بهبود تصمیم گیری تشخیص براساس مشاهدات سری زمانی $u_t, t = 0, 1, 2, \dots$ از آشکارساز بدون حافظه ANN است. فرض کنید H متغیر تصادفی است که به ازای موجود بودن هواپیما مقدار یک و در صورت موجود نبودن مقدار صفر را داراست. با فرض این که تشخیص دقیق نیست و با توجه به احتمال شرطی تعریف شده در روابط (۱-۲) و (۲-۲):

$$P(U_t = 1|H = 1) = p; \quad P(U_t = 0|H = 1) = 1 - p; \quad (1 - 2)$$

$$P(U_t = 1|H = 0) = 1 - q; \quad P(U_t = 0|H = 0) = q; \quad (2 - 2)$$

اگر خروجی پس پردازش متغیر تصادفی، u_t, t باشد جایی که $u_t = 1$ باشد هواپیما وجود دارد و $u_t = 0$ باشد، نشان می دهد موتور هواپیما غایب است. هدف از مرحله ی پس پردازش این است که احتمال هشدار خطا و احتمال از دست رفته را که با روابط (۲-۳) و (۲-۴) تعریف شده به درون محدودیت های از پیش مشخص شده بیاورد.

$$(POFA) \quad P_f = P(U_t = 1|H = 0) \quad (3 - 2)$$

$$(POM) \quad P_M = P(U_t = 0|H = 1) \quad (4 - 2)$$

در مرجع [۳] برای جمع آوری همه ی سیگنال های صوتی که در محیط می توان شنید از سنسورهای صوتی پسو استفاده می شود. در ادامه با استفاده از طبقه بند ANN، دو ویژگی ضریب انعکاسی و نسبت فرکانس عبور تیغه (BPF^۲) روتور اصلی به فرکانس عبور تیغه روتور دم و صدای ۴ هلی کوپتر شبیه سازی شده برای شناسایی هلی کوپتر استفاده می کند. مجموعه آموزش داده ها شامل ۴۰۰ فریم است که برای بهبود عملکرد شناسایی ۲۰۰ فریم آن شامل سیگنال های تمیز و ۲۰۰ فریم شامل سیگنال های تخریب شده با نسبت سیگنال به نویز ۹ دسی بل در نظر گرفته شده است. طبقه بند

^۱Moving Average

^۲Blade-Passing Frequency

ANN، ۱۰ و ۵ نرون در لایه پنهان و ۲ نرون در لایه خروجی دارد. همچنین برای ساده‌سازی ساختار شبکه عصبی از تصمیم‌گیر باینری در خروجی شبکه عصبی استفاده شده است به این ترتیب که ۴ هلی‌کوپتر مورد نظر را با (۰.۱, ۰.۱) (۰.۹, ۰.۱) (۰.۹, ۰.۹) (۰.۱, ۰.۹) هدف‌گذاری شده‌اند. جدول (۲-۴) نتایج شبیه‌سازی را نشان می‌دهد. با اضافه شدن داده‌های نویزی در آموزش، عملکرد طبقه‌بند بطور قابل توجهی افزایش یافته است. و ANN خود را به خوبی با این شرایط تطبیق داده است.

جدول (۲-۴): نتایج طبقه‌بندی [۳].

Helicopters	SNR					
	Clean	15 dB	12 dB	9 dB	6 dB	3 dB
A	100%	100%	98%	100%	98%	98%
B	100%	100%	100%	99%	98%	96%
C	97%	99%	100%	98%	99%	98%
D	100%	97%	97%	97%	95%	85%

در مرجع [۴] سیگنال صوتی چهار هلی‌کوپتر مختلف و چهار سیگنال صدای دیگرمانند موسیقی، ماشین، صدای موتور و موتور ماشین برای شناسایی استفاده می‌کند. همچنین برای استخراج ویژگی از کدینگ پیشگوی خطی (LPC)، ۲۰ نقطه‌ای و برای بهبود عملکرد سیستم تشخیص از سه نوع موجک (هار، دابیشز، یکا متعامد) برای حذف نویز سیگنال استفاده می‌کند و با استفاده از شبکه عصبی مصنوعی جلورونده (FFANN) به طبقه‌بندی نتایج می‌پردازد.

جدول (۲-۵) عملکرد طبقه‌بند را در سطوح نویزی مختلف نشان می‌دهد. زمانی که فریم‌های آزمایش شامل نویز سفید گوسی شدند SNR کاهش یافته است. و علت آن این است که در اثر اضافه شدن نویز قله‌های طیفی را منحرف می‌کند و در واقع باعث تخریب عملکرد سیگنال می‌شود. نتایج شبیه‌سازی در حالت بدون نویز تقریباً دقت تشخیص ۱۰۰٪ را دارد.

جدول (۲-۵): عملکرد LPC [۴].

Acoustic signals	Detection Accuracy			
	Clear	18dB	12dB	9dB
Helicopter S-67	100%	72%	52%	34%
Helicopter H500	99%	69%	48%	28%
Helicopter CH-47C	100%	71%	50%	32%
Helicopter MI-HIND	100%	71%	53%	31%
music	100%	84%	78%	72%
running automobile	99%	88%	72%	68%
engine sound	99%	79%	68%	62%
motor car horns	100%	80%	71%	59%

جدول (۲-۶) عملکرد طبقه‌بند را در صورت حذف نویز قبل از مرحله استخراج ویژگی نشان می‌دهد. برای این کار مطابق جدول (۲-۷) از سه موجک مادر هار، دابیشز، یکا متعامد در سه سطح تجزیه استفاده شده است که از بین آن‌ها بهترین تبدیلات موجک، یعنی: HAAR، DB2، BIOR1.1 و BIOR3.7 برای حذف نویز انتخاب شده‌اند. پس از اعمال طبقه‌بند، ۱/۲٪، ۳/۱۰٪ و ۵/۱۱٪ بهبود به ترتیب برای ۱۸، ۱۲ و ۹ دسی بل حاصل شده است.


جدول (۲-۶): نتایج براساس سیگنال حذف نویز شده [۴].

Acoustic signals	Detection Accuracy			
	Clear	18dB	12dB	9dB
Helicopter S-67	100%	92%	87%	76%
Helicopter H500	99%	91%	86%	75%
Helicopter CH-47C	100%	93%	85%	72%
Helicopter MI-HIND	100%	92%	87%	74%
music	100%	95%	84%	72%
running automobile	99%	93%	85%	78%
engine sound	99%	92%	88%	72%
motor car horns	100%	95%	86%	78%


جدول (۲-۷): انتخاب بهترین روش موجک [۴].

Signal No	WAVELET BASIS							
	HAAR	DB 2	DB 6	DB 8	BIOR 1.1	BIOR 2.8	BIOR 3.7	BIOR 5.5
1	93.74	93.74	93.69	93.67	93.74	93.66	93.67	93.69
2	92.43	92.53	92.03	91.71	92.43	92.26	92.1	92.5
3	27.45	28.83	26.06	27.85	27.45	27.71	34.81	28.17
4	63.82	65.89	71.35	72.59	63.82	70.85	68.04	69.14
5	36.76	42.97	47.37	46.88	36.76	42.25	38.28	40.3
6	93.75	93.61	93.06	92.8	93.75	92.74	92.8	93.06
7	41.89	44.35	45.83	45.48	41.89	57.78	64.49	49.84
8	54.44	54.77	54.78	54.23	54.44	55.04	53.83	54.78
Number of Selections	2	2	1	1	2	0	3	0

در مرجع [۵] روشی ارائه شده است که بتواند تشخیص دهد سیگنال دریافت شده متعلق به یک هلی- کوپتر است یا خیر و در صورت هلی کوپتر بودن نوع آن را تشخیص دهد. بدین منظور ۵ صدای هلی- کوپتر واقعی با مدت زمان پرواز ۲ دقیقه ای استفاده شده است. و سه ویژگی میزان هموار بودن طیف (SFM)، بردار انرژی بانک فیلتر با پهنای باند فیلترهای غیریکنواخت و نرخ عبور از صفر (ZCR) به همراه طبقه بند فاصله اقلیدسی وزن دار برای شناسایی استفاده شده است. روند کار در شکل های (۲-۳) و (۲-۴) آمده است.



شکل (۳-۲): روند الگوریتم تشخیص یا لگرد [۵].



شکل (۲-۴): روند الگوریتم شناسایی نوع بالگرد [۵].

جهت اندازه گیری دقت سیستم تشخیص ۱۰۰ پنجره شامل: ۶۰ پنجره از سیگنال هلی کوپتر و ۴۰ پنجره از سیگنال غیر هلی کوپتر به مرحله آزمایش (بازشناسی) الگوریتم اعمال شده و دقت تشخیص ۹۹٪ از آن حاصل شده است.

در مرجع [۷] پایگاه داده در نظر گرفته شده شامل اطلاعات فرودگاه، اطلاعات بزرگراه، سوابق صوتی و تصویری، اطلاعات محیطی و انواع هواپیماهای مختلف شامل هلی کوپتر، تک موتوره، چند موتوره و جت است. داده صوتی بعضی اوقات روی مجذور متوسط فشار سیگنال صوتی $P(t)$ پردازش می شوند.

که توسط رابطه (۵-۲) تعریف می‌شود. P_{rms} در واقع تابع نرخ نمونه‌های توان صوتی است. که واحد آن پاسکال است.

$$P_{rms} = \sqrt{\frac{1}{T_2 - T_1} \int_{T_1}^{T_2} P^2(t) dt} \quad (۵ - ۲)$$

در رابطه (۶-۲) L_p به شکل لگاریتمی توان با واحد دسی بل اشاره می‌کند.

$$L_p = 20 \log_{10} \left(\frac{P}{P_0} \right) \quad (۶ - ۲)$$


این همان سطح فشار صوتی (SPL^1) است. کمیت P_0 ، ۲۰ میکرو پاسکال است. L_p به سرعت برای تفسیر تغییر می‌کند و بعضی اوقات داده‌های زیادی برای ذخیره کردن، تولید می‌کند. به همین منظور از میانگین‌گیری برای کاهش داده‌ها استفاده می‌کند. برای داشتن سطح صوتی یکنواخت در فواصل زمانی مشخص شده رابطه‌ی (۷-۲) معرفی شده است. در واقع سیگنال صوتی L_{eq} شکل مشخصه‌ای دارد که بازتاب انواع مختلف هواپیما است و به همین خاطر از این سیگنال برای کاهش تعداد اندازه‌گیری‌ها و استخراج ویژگی برای طبقه‌بندی استفاده شده است.

$$L_{eq} = 20 \log_{10} \left(\frac{P_{rms}}{P_0} \right) \quad (۷ - ۲)$$


همانطور که از شکل‌های (۵-۲) و (۶-۲) مشخص است صدای هواپیمای جت بلند است اما صدای بلند شدن هواپیمای تک موتوره بسیار کم است. شکل (۷-۲) یک اندازه‌گیری از رابطه (۷-۲)، مقدار ماکزیمم را نشان می‌دهد. به عنوان مثال برخی سیگنال‌های صوتی مانند جت صدای بلندی دارند و برخی مانند هواپیمای تک موتوره فرود آرامی دارد. که همین باعث تفاوت در سیگنال‌های صوتی آن‌ها می‌شود. اندازه‌گیری‌های دیگر می‌تواند مرتبط با شکل منحنی باشد. بطور مثال منحنی برخی هواپیماها مانند جت به خاطر سرعت زیاد آن تیزتر است. ویژگی‌های دیگری که می‌توان استخراج کرد

¹ Sound Level Pressure


ناهمواری و تقارن منحنی مقدار ماکزیمم است. که در نهایت ۳۵ ویژگی استخراج شده خواهیم داشت به همین علت شبکه عصبی دارای ۳۵ ورودی است. و تعداد خروجی‌ها برابر با تعداد کلاس‌ها یعنی ۴ است.



شکل (۲-۵): سیگنال صوتی برخاستن هواپیمای جت [۷].




شکل (۲-۶): سیگنال صوتی برخاستن هواپیمای تک موتوره [۷].



شکل (۲-۷): اندازه گیری رابطه مقدار ماکزیمم [۷].

روش طبقه بندی درخت باینری با طبقه بند شبکه عصبی در هر نرون از درخت اجرا می‌شود. سیستم طبقه بندی درخت در شکل (۲-۸) نشان داده شده است. در واقع این سیستم یک سیستم کدینگ دودویی است که در مراحل مختلف مقایسه بین حالت انجام می‌دهد و در صورت وجود مقدار یک و در غیر این صورت مقدار صفر می‌گیرد. داده ها شامل ۱۵۳ سیگنال صوتی است که ۱۰۵ تای آن متعلق به سیگنال هواپیما و ۴۸ تای آن متعلق به وسایل نقلیه است. از این تعداد ۱۳۳ نمونه برای آموزش و ۲۰ نمونه برای آزمایش استفاده شده است. روش کار این درخت به این صورت است که نتایج حاصل از آن دقت تشخیص ۱۰۰ درصد را نشان می‌دهد.



شکل (۲-۸): طبقه بندی درخت باینری [۷].

این روش در واقع کدینگ خروجی شبکه عصبی برای دست یابی به خطای کمتر است.

در مرجع [۸] داده‌ها با قراردادن دستگاه ضبط کنار باند فرودگاه ضبط شده‌اند و شامل ۱۶۲ هواپیما در ۳۰ مدل مختلف است که در سه دسته اصلی جت‌های بزرگ، دوموتوره توربو و تک یا دو موتوره پیستونی قرار می‌گیرند. برای استخراج ویژگی از تبدیل موجک و تبدیل فوریه گسسته به کار گرفته شده‌اند. ضرایب تبدیل موجک توسط موجک دابیشز تا ۱۲ لایه برای هر کدام از رویدادها محاسبه شده است. در قسمت طبقه بندی از دو طبقه بند خانواده مجموعه فازی و شبکه عصبی استفاده شده و نتایج حاصل را با هم مقایسه کرده است. روش مجموعه فازی یک روش ساده برای ایجاد دسته ای از رویدادهاست که استحکام خاصی دارد و اجازه می‌دهد تا شناسایی‌های معقول در مجموعه های

کوچکتر رخ دهد. هر دومدل طبقه‌بند تقریباً درجه یکسانی از طبقه بندی صحیح را نشان می‌دهند و فرق بین این دو طبقه بندی در تعداد طبقات قادر به حمایت است که معمولاً در شبکه عصبی با توجه به پراکندگی داده ها ۶ و در مجموعه فازی ۲ یا ۳ است. در مجموع فازی دقت تشخیص ۹۰٪ و در شبکه عصبی ۸۶٪ بوده است.

در مرجع [۹] عملکرد پارامترهای مختلف ویژگی از قبیل کدینگ پیشگوی خطی (LPC)، ضرایب کپستروم، ضرایب انعکاسی و فرکانس‌های طیفی خطی (LSF) را با استفاده از دو گروه از هلی‌کوپترها یکی با چهار هلی‌کوپتر H500، CH-47C، MI-HIND، S-67 و دیگری با ۸ هلی‌کوپتر HH-3، S-67، H500، CH53، Mi-6، Mi-10، MI-HIND، CH-47C، برای شناسایی توسط شبکه عصبی استفاده شده است. برای دسته اول هلی‌کوپترها صداهای شبیه سازی شده به فریم‌های ۰/۱ ثانیه ای تقسیم شده‌اند. داده های آموزش از ۲۸۰ فریم تشکیل‌اند که ۷۰ تا برای هر هلی‌کوپتر است. شماره فریم‌های ۱ و ۵ و ۹ و ۱۱ از هر هلی‌کوپتر برای آموزش و فریم های ۳ و ۷ و ۱۱ و ۱۳ برای آزمایش شبکه عصبی استفاده شده‌اند. در ادامه فریم‌ها با اضافه شدن نویز سفید گوسی با نسبت سیگنال به نویز (SNR) ۱۲، ۹ و ۳ دسی بل تخریب می‌شوند تا نیرومندی عملکرد آنها توسط شبکه عصبی تست شود. هلی‌کوپترها با هدف‌های (۰.۱ ۰.۱) (۰.۱ ۰.۹) (۰.۹ ۰.۱) (۰.۹ ۰.۹) در نظر گرفته شده‌اند. آموزش طبقه بند ANN زمانی متوقف می‌شود که مربع خطا (SSE) به آستانه مناسب هدف برسد یا بهبود در SSE قابل چشم پوشی باشد. در مورد ضرایب LPC، ضرایب انعکاسی و ضرایب کپستروم هر فریم صدای ۰/۱ ثانیه ی به بردار ویژگی ۲۰ نقطه ای کد شده است. برای LSF بعد بردار ویژگی به ۱۴ محدود شد زیرا مقداری ناپایداری عددی در الگوریتم پیدا کردن ریشه رخ می‌داد. چهار طبقه بند ANN ساخته شد که هر کدام دو لایه پنهان از نرون ها به ترتیب ۱۴ و ۷ نرون را دارا می باشند و دونرون در لایه خروجی قرار دارد.

برای دسته دوم هلی کوپترها صداهای شبیه سازی شده به فریم‌های ۰/۱ ثانیه ای تقسیم شده‌اند. داده های آموزش از ۸۰۰ فریم (۱۰۰ فریم برای هر هلی کوپتر) و داده های آزمایش از ۴۰۰ فریم (۵۰ فریم برای هر هلی کوپتر) تشکیل شده‌اند. طبقه بند ANN ۱۰ و ۵ نرون در لایه پنهان و ۳ نرون در لایه خروجی دارد. بنابراین هدف خروجی توسط جدول (۲-۸) تعریف می‌شود.

جدول (۲-۸): تابع هدف خروجی برای ۸ هلی کوپتر [۹].

	A	B	C	D	E	F	G	H
y_3	0.1	0.1	0.1	0.1	0.9	0.9	0.9	0.9
y_2	0.1	0.1	0.9	0.9	0.1	0.1	0.9	0.9
y_1	0.1	0.9	0.1	0.9	0.1	0.9	0.1	0.9

در نهایت عملکرد این طبقه بند در حالت داده های تست شده بدون نویز و با نویز با هم مقایسه شده است. جدول (۲-۹) نتایج حاصل از طبقه‌بندی ۴ هلی کوپتر را نشان می‌دهد. با توجه به جدول (۲-۹) تأثیر نویز این است که فرمنت های صوت را کاهش می‌دهد و طیف سیگنال را هموار میکند. قطب های فیلتر LPC بسمت منبع و درون دایره واحد حرکت می‌کنند. وقتی پارامترهای LPC بعنوان بردار ویژگی استفاده می‌شود ضرایب آن از طریق جمع صفرهای $A(z)$ بدست می‌آید. و در واقع تأثیر نویز کاهش ارزش بالاترین ضریب LPC است. حتی کاهش طیف محلی می‌تواند نتیجه تغییر مهم در ارزش این ضرایب بالا باشد. و در زمان وقوع نویز ضرایب LPC همه هلی کوپترها گرایش به مقادیر کمتر دارند. رنج محدود ضریب انعکاسی در واقع عملکرد طبقه بند ANN را بهبود می‌دهد. هر ضریب انعکاسی به بهبود همه مدل طیف کمک می‌کند. به بیان دیگر تغییرات در طیف بصورت پله ای توسط همه ضرایب بدون ایجاد تغییرات اساسی در ضرایب مرتبه بالا مانند ضرایب LPC ، اجرا می‌شود.

جدول (۲-۹): درصد طبقه‌بندی صحیح [۹].

Feature Type	Signal/Noise	Helicopter Type			
		A	B	C	D
LP Coefficients	Clean	100	100	98.5	100
	12 dB	38.5	92.9	100	51.4
	9 dB	21.5	78.5	100	34.3
	3 dB	8.5	48.5	98.5	20
Reflection Coefficients	Clean	100	100	100	100
	12 dB	100	44.3	100	98.5
	9 dB	100	37.2	100	91.4
	3 dB	98.5	22.9	100	71.3
Cepstrum Coefficients	Clean	100	100	100	100
	12 dB	78.6	28.6	100	12.9
	9 dB	21.4	7.2	100	2.9
	3 dB	8.6	0	100	0
LSF	Clean	100	100	100	100
	12 dB	100	100	100	62.9
	9 dB	90	98.5	100	42.9
	3 dB	45.7	91.4	100	37.1

جدول (۲-۱۰) نتایج حاصل از طبقه‌بندی ۸ مدل هلی‌کوپتر را نشان می‌دهد. که در آن عملکرد ضعیف B, E, G بخاطر این است که هارمونیک صدای روتور اصلی آنها با یکدیگر هم‌پوشانی دارد و در مقابله با نویز قوی زمانیکه طیف هلی‌کوپتر G بیش از حد تار و نا مشخص می‌شود اشتباهاً H تشخیص داده می‌شود و هلی‌کوپتر E اشتباهاً F تشخیص داده می‌شود. اگر بردار ویژگی بزرگی استفاده شود ضریب انعکاسی، بهبود عملکرد را نشان می‌دهد. به عنوان مثال با بردار ویژگی شامل ۳۰ ضریب انعکاسی ۱۰۰ درصد تشخیص درست در نسبت سیگنال به نویز ۹ dB و میانگین ۹۷/۷۵ در ۳ dB دارد. تکنیک LSF نیرومندی قابل توجهی مقابل نویز را نشان می‌دهد که با تکنیک های دیگر مقایسه شده است.

جدول (۲-۱۰): نتایج طبقه‌بندی با استفاده از سیگنال‌های تمیز [۹].

Classification Results of Helicopter	SNR					
	Clean	15 dB	12 dB	9 dB	6 dB	3 dB
A	100%	100%	100%	100%	96%	96%
B	100%	48%	22%	0%	4%	0%
C	96%	100%	100%	100%	98%	94%
D	98%	82%	84%	74%	70%	74%
E	98%	26%	12%	4%	0%	0%
F	98%	82%	78%	72%	60%	50%
G	100%	2%	2%	0%	2%	0%
H	100%	98%	98%	92%	80%	66%

برای بهبود عملکرد شناسایی ANN را با فریم‌های نویزی و تمیز آموزش می‌دهیم. در واقع ۴۰۰ فریم با نویز ۹ دسی بل تخریب شده و ۴۰۰ فریم تمیز هستند. جدول (۲-۱۱) نتایج شبیه سازی نشان‌دهنده بهبود قابل توجهی است.

جدول (۲-۱۱): نتایج طبقه‌بندی با استفاده از سیگنال‌های تمیز و نویزی در آموزش [۹].

Classification Results of Helicopter	SNR					
	Clean	15 dB	12 dB	9 dB	6 dB	3 dB
A	100%	100%	98%	100%	98%	98%
B	100%	100%	100%	100%	98%	96%
C	98%	100%	100%	98%	100%	100%
D	100%	98%	98%	98%	96%	88%
E	98%	98%	98%	94%	78%	78%
F	100%	98%	100%	100%	96%	88%
G	100%	88%	92%	84%	82%	48%
H	100%	100%	100%	100%	100%	84%

مرجع [۱۰] از صدای هلی‌کوپتر و تعدادی صدای غیر هلی‌کوپتر برای آموزش شبکه عصبی مصنوعی چند لایه جلورونده (FFANN) برای سیستم شناسایی استفاده کرده است. که البته برخلاف مطالعات دیگر از باند میانی طیف سیگنال هلی‌کوپتر برای استخراج بردار ویژگی استفاده کرده است. همچنین از الگوریتم گورتزل (GFFT) برای ارزیابی طیف در فرکانس انتخاب شده ۳۵۰-۱۶۰ هرتز استفاده شده است. طبقه بند ANN ۱۵ نرون در لایه پنهان و یک نرون در لایه خروجی دارد. نتایج بدست آمده تشخیص صحیح با نرخ ۹۹/۵٪ را نشان می‌دهد.

در مراجع [۱۱، ۱۲] شبکه عصبی مصنوعی چند لایه جلورونده برای شناسایی دو هلی‌کوپتر آموزش داده شده است. و از فرکانس عبور تیغه اصلی روتور، نسبت فرکانس‌های عبور از تیغه اصلی و تیغه دم و قله‌های انتخاب شده از دامنه طیفی هفت هارمونیک اصلی نویز روتور اصلی به عنوان بردارهای ویژگی استفاده شده است. و با توجه به نتایج بدست آمده طبقه بند ANN نرخ تشخیص ۶۵ درصدی داشته مقاومت خوبی در برابر نویز را نشان می‌دهد.

در مرجع [۱۳] یک سیستم تشخیص برای شناسایی هلی کوپتر، هواپیمای جت، پروانه هواپیما، توربین بادی و قطار با استفاده از داده‌های صوتی مبتنی بر تصمیم‌گیری درختی ارائه شده است. ویژگی‌های مورد استفاده از طیف فوریه و تابع خود همبستگی سیگنال‌ها استخراج شده است. نتایج حاصل از این سیستم تشخیص دقت ۹۰ درصدی را نشان می‌دهد.

در مرجع [۱۴] طبقه‌بند برای طبقه‌بندی منابع صوتی ناشناخته مانند هواپیمای جت، هواپیما، ملخ‌دار، هلی کوپتر و یا توربین بادی با استفاده از داده‌های یک میکروفون طراحی شده است. با توجه به پیچیده بودن ماهیت طبقات، طبقه‌بند داده‌ها را با استفاده از الگوهای شناخته شده آموزش می‌دهد. همچنین شبکه عصبی پرسپترون چند لایه به عنوان جایگزینی برای تصمیم‌گیر درختی آزمایش شده است. در مجموعه داده‌های مشابه، نتایج نشان می‌دهد که شبکه عصبی بیش از ۸۱ درصد منابع را به درستی شناسایی می‌کند.

۴.۲) جمع بندی

در چند دهه اخیر روش‌های مختلفی در پردازش صوت برای تشخیص نوع هواپیما مطرح شده است. که در این پایان‌نامه سعی شده است شاخص‌ترین روش‌ها مورد بررسی قرار گیرند و از بین آن‌ها کارآمدترین روش‌ها معرفی گردد. در این فصل به بررسی پژوهش‌های انجام شده و تحلیل نتایج حاصل از آن پرداختیم. تا بتوانیم برای کار آینده از آن‌ها بهره بگیریم.

فصل سوم: مبانی نظری

۱.۳) پیشگفتار

تشخیص نوع هواپیما با استفاده از روش‌های پردازش صوت شامل مراحل مختلفی از قبیل ضبط صدا و ذخیره آن توسط روش‌های مختلف، تبدیل سیگنال ذخیره شده به یک سیگنال دیجیتال، اعمال پیش پردازش روی سیگنال به جهت حذف نویز و فریم بندی سیگنال جهت ایستادن در نظر گرفتن سیگنال در هر فریم، استخراج ویژگی از صدای سیگنال صوتی پردازش شده و استفاده از یک طبقه-بند مانند شبکه عصبی برای طبقه بندی ویژگی‌ها تشکیل شده است. در این فصل به بررسی روابط و تئوری مراحل ذکر شده می‌پردازیم تا در فصل چهارم از آن‌ها برای شبیه سازی و نمایش نتایج استفاده کنیم.

۲.۳) جمع‌آوری داده و ضبط صدا


۱.۲.۳) سخت افزار ASAD

ارتعاشات صدای هواپیما برای تشخیص، ردیابی و طبقه‌بندی آنها توسط سیستم پیشرفته صوتی تشخیص ارتعاش هوا (^۱ASAD) استفاده می‌شود. داده‌ها بصورت قرار دادن دستگاه ضبط کنار باند فرودگاه ضبط میشوند. بطور مثال دستگاه ASAD شامل چندین گره میکروفون و ژئوفون^۲ است و ایستگاههای میدان با هر گره متشکل از ۸ کانال، ۵ کانال میکروفون و ۳ کانال ژئوفون است [۲]. شکل (۱-۳) شماتیک کلی سیستم را نشان میدهد. شکل (۲-۳) تصویری از سیستم ASAD، که در منطقه کوهستانی مستقر شده را نشان میدهد. فاصله بین جفت میکروفون‌های افقی ۸ اینچ و میکروفونی که در رأس نصب شده در ارتفاع ۱۲ اینچی قرار دارد. سنسورهای میکروفون شامل ۶۴ میکروفون کپسولی است که هدایت، نویز داخلی کم و حساسیت بالا دارد. هر دسته میکروفون تقریباً ۱.۵ فوت

^۱Acoustic Seismic Aircraft Detection

^۲ Geophone

طول دارد و متشکل از ۶۴ میکروفون کپسولی است که در یک ردیف ۸ کاناله که بصورت شکل زیر گروه شده اند [۲].




شکل (۳-۱): شماتیکی از سیستم تشخیص ارتعاش هوا (ASAD) [۲].



شکل (۳-۲): تصویر سیستم تشخیص ارتعاش هوا (ASAD) [۲].

داده های صوتی از هر گروه جمع آوری شده و به جعبه پردازش اولیه سیگنال فرستاده میشود.



شکل (۳-۳): شماتیکی از میکروفون خوشه ای که شامل ۶۴ میکروفون است [۲].

میکروفون، سطح بالایی از سیگنال را تولید میکند. بنابراین نیازی به تقویت کننده اضافی بین خروجی و ورودی نیست. ارتعاش سطح توسط ژئوفون ضبط می‌شود. همچنین از ژئوفونی استفاده میکنیم که پاسخ ولتاژ دارد یعنی ورودی را تبدیل به ولتاژ کرده و انتقال میدهد که با توجه به سرعت و سطح فشار صدا کالیبره شده است. سیگنالهای ثبت شده توسط دسته میکروفون و ژئوفون توسط جعبه الکترونیک نشان داده شده در شکل (۳-۳) پردازش میشود. جعبه الکترونیکی سیگنالهای ژئوفون را تقویت میکند، سیگنالهای رسیده از میکروفون و ژئوفون را فیلتر و دیجیتالی می‌کند. و همچنین پردازش اولیه سیگنال را انجام میدهد [۲].

۲.۲.۳) سنسورهای پسیو

وقتی یک جسم به اندازه کافی نزدیک زمین پرواز می‌کند و مسیرش را دنبال می‌کند تقریباً برای هر سیستم تشخیصی در تجزیه و تحلیل سیگنالهای پراکنده نامرئی است. این غیر قابل اعتماد بودن رادار سنتی، همراه با ناتوانی اش در شناسایی بدون شبهه اجسام تشخیص داده شده استفاده از سیستم تشخیص براساس سنسور پسیو را تحریک کرده است. سنسورهای صوتی پسیو برای جمع-آوری همه‌ی سیگنال‌های صوتی که در محیط می‌توان شنید استفاده می‌شود. این سنسورها هیچ سیگنالی از خودشان ارسال نمی‌کنند بنابراین مکان فیزیکی خود را نشان نمی‌دهند [۳].

۳.۳) پیش پردازش

قبل از استخراج ویژگی از سیگنال صوتی مرحله پیش پردازش قرارداد که شامل اعمال فیلتر پیش تأکید و فریم بندی سیگنال است. فیلتر پیش تأکید، فیلتری بالاگذر است که تغییرات ناگهانی موجود در سیگنال که بر اثر نویزهای شدید محیط به وجود می‌آید را حذف میکند و سیگنال را یکنواخت می‌کند. که معادله آن مطابق رابطه (۳-۱) است. در اینجا a ، $0.9 \leq a \leq 1$ در نظر گرفته شده است [۱].

$$y(n) = x(n) - ax(n-1), 0.9 \leq a \leq 1 \quad (3-1)$$

۴.۳) اعمال پنجره


سیگنال صوتی یک سیگنال ایستا نیست و مشخصات فرکانسی آن با زمان تغییر می‌کند. اما خیلی از ابزارهای در دسترس ما جهت تشخیص ویژگی مناسب سیگنال ایستا می‌باشد. زمانی که سیگنال صوتی را مورد بررسی قرار می‌دهیم آن را به قسمت‌های کوتاه زمانی تقسیم می‌کنیم و هر قسمت را جداگانه آنالیز می‌کنیم، بدلیل اینکه سیگنال را بتوانیم ایستا در نظر بگیریم. این عمل را فریم بندی یا windowing می‌نامند برای اینکار سیگنال را از یک فیلتر عبور می‌دهیم که در بازه زمانی مورد نظر ما مقدارش یک و در بقیه زمانها صفر است. بنابراین سیگنال خروجی در بازه زمانی مطلوب ما همان مقدار قبلی خود را دارد و در بقیه زمانها صفر است. در اینجا از پنجره همینگ^۱ به عنوان فیلتر استفاده کرده ایم. این پنجره در ابتدا و انتها مقادیری نزدیک به صفر داشته و این مقدار در نزدیک پنجره به مرور به صفر نزدیک می‌شود. همچنین برای نتیجه گیری بهتر با خطای کمتر و از بین رفتن کمتر اطلاعات سیگنال صوت، پنجره گذاری را به گونه ای انجام می‌دهیم که مقداری هم‌پوشانی یا overlap بین پنجره ها وجود داشته باشد [۱].

^۱hamming

۵.۳ استخراج ویژگی ها

انتخاب پارامترهای ویژگی داده ها بسیار مهم است زیرا بر کل عملکرد شناسایی سیستم تأثیر دارد. شکل (۳-۴) مجموعه عملیات درگیر در استخراج ویژگی را مناسب برای فرآیند طبقه بندی نشان می دهد.

اولین مرحله تقسیم بندی سیگنال صوتی ورودی به فریم هاست که قبل از آن آنالیز دیجیتالی می- شوند. مشخصه های صدای هواپیما در فریم های $0.5 - 0.05$ می تواند ایستا در نظر گرفته شوند. [۱] مؤلفه های غالب سیگنال هلی کوپتر در رنج فرکانسی زیر 2 kHz قرار دارد. بنابراین فیلتر پایین گذر با فرکانس قطع 2 kHz برای فیلتر کردن سیگنال استفاده شده است. این مرحله پردازش یکسری اطلاعات نامربوط را حذف می کند و توانایی پایین نمونه برداری سیگنال را به ما می دهد. مشخصات ضروری صدای هلی کوپتر نسبتاً به کندی تغییر می کند که اجازه نمایش اطلاعات مهم کمتری را می دهد. مرحله ی بعد شامل ضرب سیگنال در یک پنجره هموار با طول محدود است. انتخاب نوع پنجره (شکل و طول) بر رزولوشن زمان و فرکانس تأثیر می گذارد. بردار ویژگی از این سیگنال های پنجره شده بدست می آید [۱].



شکل (۳-۴): بلوک دیاگرام برای استخراج ویژگی [۱].

در این پایان‌نامه از انرژی تبدیل موجک، ضرایب پیشگوی خطی (LPC^1)، $MFCC^2$ ، LSF^3 و کپستروم حقیقی (RC^4) برای استخراج ویژگی استفاده شده است.

۱.۵.۳ تبدیل موجک

تبدیل موجک یکی از بهترین روشهای استخراج رفتار زمانی به شیوه سازگار ریاضی و علمی است. سیگنال صوتی هلی کوپتر و هواپیماهای جت مانند یک فرآیند نا ایستان است. بنابراین برای آنالیز سیگنال صوتی نیاز است که ابزار لازم برای پردازش فرآیند نا ایستان را داشته باشد. روش آنالیز موجک بدین صورت است که سائز پنجره ثابت است ولی شکل آن میتواند تغییر کند. پنجره زمانی و پنجره فرکانسی ممکن است با روش آنالیز محلی سازی زمان_فرکانس را تغییر دهند. در قسمت فرکانس بالا رزولوشن (درجه زوم) بالا و طول پنجره زمانی کم را داریم و در قسمت فرکانس پایین رزولوشن پایین و طول پنجره زمانی بالا را داریم. به همین علت تبدیل موجک به عنوان میکروسکوپ ریاضی شناخته شده است. بنابراین استخراج ویژگی از طریق تبدیل موجک دارای ثبات است. تبدیل موجک در واقع فرآیند فیلتر شدن سیگنال اصلی است. فضای سیگنال هموار و سیگنال جزئیات میتوان فرکانس سیگنال اصلی را وقتی اطلاعات محلی شده اند ارائه دهد. به خصوص میتواند فرکانس های مختلف را ارائه دهد. اگر برای هر انرژی خروجی در تجزیه، سیگنال مقیاس متفاوتی باشد. پس با توجه به آن مقیاس، میتوان بردار ویژگی آن را شناسایی کرد، این پایه اصلی تبدیل موجک برای استخراج مشخصات انرژی چند مقیاسی است [۶].

تبدیل موجک سیگنال دریافتی $f(t)$ را در هر دو حوزه زمان و فرکانس به جمع توابع پایه وزن دار تجزیه می‌کند. توابع پایه نسخه‌های ترجمه شده و بسط داده شده از موجک مادر هستند. توابع موجک مادر انواع مختلفی دارد مانند موجک هار، دابیشز و یکامتعامل. یک روش کارآمد برای محاسبه تبدیل


¹Linear Predictive Coding

²Mel Frequency Cepstrum Coefficient

³Line Spectral Frequency

⁴Real Cepstrum

موجک استفاده از یک جفت فیلتر بانک طراحی شده‌ی مناسب و سپس پایین نمونه برداری از آن با فاکتور ۲ است. که این جفت فیلتر از یک فیلتر پایین گذر H و یک فیلتر بالاگذر G تشکیل شده است. که در نتیجه این تجزیه پهنای باند سیگنال نصف می‌شود. باتوجه به شکل (۳-۵) سیگنال اصلی را می‌توان با معکوس کردن روش توضیح داده شده بازسازی کرد [۴].



شکل (۳-۵): اجرای تبدیل موجک و معکوس آن [۴].

همانطور که مشخص است با استفاده از این تبدیل سیگنال اصلی قابل بازسازی است. شکل پنجره زمان_فرکانس بعد از تبدیل موجک، مستطیل با ابعاد $[(\mp w_0 + \Delta\hat{\varphi}/a), [b - a\Delta\varphi, b + a\Delta\varphi] * [(\mp w_0 + \Delta\hat{\varphi}/a)]$ هستند. مرکز پنجره $(b, \mp w_0/a)$ است، عرض پنجره و عرض فرکانس پنجره به ترتیب $a\Delta\varphi$ و $\Delta\hat{\varphi}/a$ هستند. b تنها روی مکان محور زمان در صفحه فازی تأثیر می‌گذارد. بنابراین تبدیل موجک برای نمونه برداری در فرکانسهای مختلف در حوزه زمان، طول گام قابل تنظیمی دارد. در تبدیل موجک در فرکانس پایین رزولوشن زمانی ضعیف‌تر است و برعکس. در سیگنال فرکانس پایین، تغییرات سیگنال کم است و در فرکانس بالا تغییرات زیادی داریم [۶].

طول تابع موجک φ و تابع مقیاس $\emptyset$ ، $2N-1$ است. و مرتبه ممانهای صفر شونده تابع موجک φ ، N است. dbN معمولاً تقارن ندارد برای برخی از توابع موجک عدم تقارن واضح است. زمانی که مقدار N افزایش می‌یابد ویژگی‌های سیگنال بطور منظم افزایش می‌یابد و در آن واحد تابع یکامتعامد است [۶].

۲.۵.۳ ضرایب پیشگوی خطی (LPC)

ضرایب پیشگوی خطی (LPC) یکی از قویترین روش های آنالیز صداست که تخمین های بسیار دقیقی از پارامترهای صدا را فراهم می کند به همین خاطر LPC را به عنوان نماینده پارامتری از طیف هواپیما در نظر می گیریم. آنالیز پیشگوی خطی به ماکزیمم محلی بیشتر از مینیمم محلی وزن می دهد. مدلی که برای بیان طیف داده های ورودی استفاده می شود از رابطه (۲-۳) بدست می آید [۹].


$$S(e^{j\theta}) = \frac{G}{A(z)} \big|_{z = e^{j\theta}} \quad (2-3)$$

G فاکتور مقیاس است و $A(z)$ از طریق رابطه (۳-۳) بدست می آید.

$$A(z) = 1 + \sum a_i z^{-i} \quad (3-3)$$

به عنوان مثال اگر سیگنال بعد از پنجره گذاری ۲۵۶ نمونه داشته باشد و با تعداد p ضریب آن را مدل کنیم به جای ارسال ۲۵۶ نمونه برای هر فریم کفایت p عدد، ضریب را ارسال کنیم. در این صورت برای هر فریم p معادله و p مجهول خواهیم داشت.

نمونه های آکوستیک S_n می تواند به عنوان خروجی سیستم به همراه برخی ورودی ناشناخته U_n با استفاده از p نمونه قبلی خروجی در نظر گرفته شوند. سیگنال S_n تقریباً می تواند از جمع نمونه های قبلی وزن دار خطی پیش بینی شود. تقریب S_n را $\hat{S}_n$ در نظر بگیرید [۱۸].



شکل (۳-۶): سنتز صوتی تولید شده توسط مدل LPC [۴].

$$\hat{s}_n = -\sum_{k=1}^p a_k s_{n-k} \quad (3-4)$$

در رابطه (3-4)، a_k از طریق مینیمم سازی حداقل مربعات به دست می آید. هریک از این پارامترها به عنوان بردار ویژگی در نظر گرفته میشوند. خطای پیش بینی از رابطه زیر بدست می آید [4].

$$e_n = s_n - \hat{s}_n \quad (3-5)$$

$$e_n = s_n + \sum_{k=1}^p a_k s_{n-k} \quad (3-6)$$

$$E_{\hat{n}} = \sum_m e_{\hat{n}}^2 = \sum_m (s_{\hat{n}}(m) - \widehat{s_{\hat{n}}}(m))^2 = \sum_m (s_{\hat{n}}(m) - \sum_{k=1}^p a_k s_{\hat{n}}(m-k))^2 \quad (3-7)$$

۳.۵.۳ فرکانس های طیفی خط (LSF)

فرکانس های طیفی خط (LSF) تحت عنوان جفت های طیفی خط، جایگزین پارامترهای فیلتر تمام قطب با تناظر یک به یک با ضرایب پیشگوی خطی (LPC) نیز شناخته می شوند [9]. مفهوم LSF اولین بار توسط ایتاکورا [۱۹] مطرح شد. LSF به علت رابطه نزدیک با قله های طیفی در بازیابی اطلاعات سیگنال صوتی کارآمدتر از دیگر پارامترهای طیفی نظیر (نسبت لگاریتم- مساحت ، تبدیل معکوس سینوسی) عمل میکند. پارامترهای LSF بازه ی حرکت دینامیکی خوبی دارند و در خطر تغییرات کمتری قرار دارند.

بدست آوردن LSF از روی ضرایب LPC، از چند جمله ای $A(z)$ که در رابطه ی (3-3) تعریف شده، شروع می شود. تابع سیستم معکوس زمانی مطابق رابطه ی (3-۸) تعریف می شود.

$$B(z) = z^{-(P+1)} A(z^{-1}) \quad (3-8)$$

حالا با استفاده از $A(z)$ و $B(z)$ بدست آمده از روابط (3-3) و (3-۸) دو رابطه کمکی (3-۹) و (3-۱۰) را تعریف می کنیم.

$$P(z) = A(z) + B(z) \quad (9-3)$$

$$Q(z) = A(z) - B(z) \quad (10-3)$$

حتی می‌توان $P(z)$ و $Q(z)$ را به ازای مقادیر مختلف p با استفاده از روابط $(3-11)$ و $(3-12)$ بدست آورد.

$$P(z) = (1+z^{-1}) \prod_{i=1,3,\dots}^{p-1} (1 - 2z^{-1} \cos \omega_i + z^{-2}) \quad (11-3)$$

$$Q(z) = (1+z^{-1}) \prod_{i=2,4,\dots}^{p-1} (1 - 2z^{-1} \cos \omega_i + z^{-2}) \quad (12-3)$$

در روابط $(3-11)$ و $(3-12)$ ω_i مقادیر واقعی هستند و برابر با زاویه ریشه‌های قرار گرفته روی دایره واحد است. و پارامترهای ω_i همان فرکانس‌های طیفی خط (LSF) هستند. اگر تمام ریشه‌های چندجمله‌ای LP اصلی داخل دایره واحد باشد LSF باید با رابطه‌ی $(3-13)$ مرتبط باشد.


$$\omega_0 < \omega_1 < \dots < \omega_p < \omega_{p+1} \quad (13-3)$$

زیرا ریشه‌های دو چندجمله‌ای در این حالت با هم برخورد خواهد داشت و این نشان می‌دهد که اگر فیلتر سنتز پایدار باشد، LSF آن را می‌توان به عنوان یک مجموعه منظم از اعداد واقعی نمایش داد [۹].

۴.۵.۳ ضرایب کپستروم فرکانس مل (MFCC)

رایج‌ترین و غالب‌ترین روش که برای استخراج ویژگی استفاده می‌شود محاسبه ضرایب کپستروال فرکانس مل (MFCC) است. MFCC یکی از معروف‌ترین تکنیک‌های استخراج ویژگی است که در شناسایی گفتار براساس حوزه فرکانس است و از مقیاس مل که بر اساس مقیاس شنوایی گوش انسان تعریف می‌شود، استفاده می‌کند [۲۰].

MFCC به عنوان ویژگی حوزه فرکانسی مطرح می‌شود که از ویژگی‌های حوزه زمان دقیق‌تر است. ضرایب کپسترال فرکانس مل در واقع نمایش کپسترال حقیقی است که به سیگنال‌های زمان کوتاه پنجره بندی شده مشتق از تبدیل فوریه سریع (FFT) سیگنال تبدیل شده‌است. تفاوتش از کپسترال حقیقی این است که مقیاس فرکانس غیر خطی استفاده شده است، که رفتار سیستم شنوایی را تقریب می‌زند. به علاوه، این ضرایب نسبت به نوسانات شرایط بلندگو و ضبط صدا مقاوم و قابل اطمینان است. MFCC تکنیک استخراج ویژگی صوتی است که پارامترها را به گونه‌ای از گفتار استخراج می‌کند که توسط انسان برای شنیدن گفتار استفاده می‌شود. در دیاگرام شکل (۷-۳) مراحل استخراج ویژگی MFCC نشان داده شده است [۲۱].



شکل (۷-۳): دیاگرام مشتقات MFCC [۲۰].

در اولین قدم سیگنال صوتی به فریم‌های زمانی شامل تعداد اختیاری نمونه‌ها تقسیم می‌شود. در بیشتر سیستم‌ها، هم‌پوشانی بین فریم‌ها برای هموارسازی گذرای فریم به فریم استفاده می‌شود. سپس فریم‌ها توسط پنجره همینگ، پنجره گذاری میشوند تا ناپیوستگی در لبه‌ها حذف شوند. سپس

برای هر فریم تبدیل فوریه سریع (FFT) آن برای استخراج مؤلفه‌های فرکانسی از سیگنال حوزه‌ی زمان محاسبه می‌شود. در واقع FFT برای سرعت بخشیدن به پردازش استفاده شده است. فیلتر بانک مقیاس مل فرکانسی بر فریم‌های تبدیل فوریه اعمال شده است. این مقیاس تقریباً زیر ۱KHz خطی است و بالای ۱KHz در فرکانس‌های بیشتر لگاریتمی است. رابطه (۳-۱۴)، ارتباط بین فرکانس سیگنال و مقیاس مل را نشان می‌دهد [۲۰].

$$\text{Mel}(f) = [2595 \log(1 + f(\text{Hz})/700)] \quad (3-14)$$

در فیلتر بانک مقیاس مل در فرکانس‌های بالای فیلتر پهنای باند بهتری نسبت به فرکانس‌های پایین دارد. آخرین مرحله محاسبه تبدیل کسینوسی گسسته (DCT) از خروجی فیلتربانک است. برای هر فریم مجموعه‌ای از MFCC محاسبه شده است. این مجموعه ضرایب، بردارهای صوتی نامیده می‌شوند که مشخصه‌های مهمی از سیگنال را نمایش می‌دهد که در آنالیزها و پردازش‌ها بسیار مفید و کارآمد هستند. اگر ۲ ثانیه از یک سیگنال صوتی را در نظر بگیریم تقریباً ۱۲۸ فریم دارد که با سائز پنجره ۱۶ میلی ثانیه هر فریم شامل ۱۲۸ نمونه است. می‌توان ۲۰ تا ۴۰ فریم را در نظر گرفت که تقریب خوبی از سیگنال را به ما می‌دهد. از مجموع ۴۲ پارامتر MFCC، ۱۲ تای آن اصلی، ۱۲ تا مربوط به مشتق اول، ۱۲ تا مربوط به مشتق دوم، ۳ تا مربوط به لگاریتم انرژی و سه تای نهایی مربوط به ضریب صفرم یا همان انرژی است. تعداد ضرایب مورد استفاده در این پایان‌نامه ۳۹ بوده است [۲۰].

۷.۵.۳ ضرایب کپستروم


آنالیز کپستروم روشی متناوب برای بدست آوردن بردار ویژگی طیفی است. کپستروم سیگنال، تبدیل فوریه لگاریتم طیف است که G_n ضرایب کپستروم آن است. این ضرایب توسط رابطه (۳-۱۵) محاسبه می‌شوند که با توجه به این رابطه $s(e^{jw})$ طیف سیگنالی است که ضرایب کپستروم از روی آن محاسبه می‌شود [۹].

$$\ln |s(e^{jw})|^2 = \sum_{n=-\infty}^{\infty} c_n e^{-jw} \quad (۱۵-۳)$$

می‌توان با استفاده از یک الگوریتم بازگشتی ضرایب کپستروم را با استفاده از ضرایب LP بدست آورد. آنالیز کپستروم روش جایگزین دیگری برای بدست آوردن بردار ویژگی طیفی است. یکی از مزیت‌های آنالیز کپستروم این است که پاسخ فرکانسی اعوجاج‌هایی دارد که توسط سیستم انتقال معرفی شده حذف می‌شود.

۶.۳) تکنیک طبقه بندی

در این پایان‌نامه از شبکه عصبی مصنوعی (ANN^۱) برای ساخت طبقه بند و شناسایی کننده در سیستم آشکار سازی صدا بخاطر قدرت پردازش و سرعت آن استفاده شده است. سیستم طبقه بندی الگو برای طبقه بندی هدف بر اساس دانسته های قبلی از ویژگی انجام می‌شود. و سیستم‌هایی هستند که در دوفاز آزمایش و مرحله آموزش عمل می‌کنند. سیستم طبقه بندی الگو از استخراج کننده ویژگی و طبقه بند تشکیل شده است. استخراج کننده ویژگی داده های جمع آوری شده را نرمالیزه میکند. اطلاعات غیر مرتبط را حذف می‌کند و آنها را به پارامترهای ویژگی تبدیل می‌کند. طبقه بند این ویژگی ها را می‌گیرد و تلاش می‌کند در میان هدف آنها را در کلاس‌های مختلف متمایز کند. سیستم طبقه بندی الگو را در شکل (۳-۸) مشاهده می‌کنید [۸].




شکل (۳-۸): سیستم طبقه بندی الگو [۸].

^۱ Artificial Neural Network

۱.۶.۳) شبکه عصبی مصنوعی جلو رونده (FFANN^۱)

یک شبکه عصبی مصنوعی جلو رونده (FFANN) که به عنوان طبقه بند در این قسمت بررسی می-شود قابلیت یادگیری از نمونه ها، توانایی تولید توابع غیرخطی دلخواه از ورودی و ساختار موازی و منظم از شبکه عصبی مصنوعی (ANN) آن را به الگویی مناسب برای طبقه بندی تبدیل کرده است. بردار ویژگی به عنوان ورودی این شبکه هستند. ANN در شرایطی که در آن تعیین کردن کمیت خواص آماری پدیده ها مانند سیگنال هلی کوپتر دشوار است، برتر است. در مرحله آموزش، شبکه پارامترهای متغیر خود را تنظیم میکند. که آن را وزن سیناپسی می نامند [۴].


برای گرفتن ویژگی های ورودی، FFANN شامل عناصر پردازش ساده به نام نرون است. مطابق شکل (۳-۱۰) هر نرون اساساً گره جمع گر وزن است که با تابع اسکالر غیر کاهشی خروجی که تابع فعال سازی نامیده می شود، دنبال می شود. این نرون ها یک ساختار چند لایه پیوسته مطابق شکل (۳-۹) دارند. همچنین الگوریتم انتشار از عقب (BP^۲) برای آموزش این شبکه استفاده می شود [۴، ۱۶].



شکل (۳-۹): FFANN چند لایه [۴].

^۱Feed Forward Artificial Neural Network

^۲Back Propagation



شکل (۳-۱۰): نرون‌های مدل شده [۹].

تابع فعالسازی که با $f(.)$ نمایش می‌دهیم خروجی نرون‌ها را براساس سطح فعالیت ورودی آن تعیین می‌کند. انواع مختلفی از توابع فعالسازی غیر خطی می‌توانند استفاده شوند. به عنوان مثال برای شکل (۳-۹) در لایه‌های پنهان تابع sigmoid یا hyperbolic tangent sigmoid و برای لایه خروجی هر تابع فعالسازی دیگری استفاده می‌شود. روابط مربوط به تابع فعالسازی بصورت زیر تعریف می‌شود [۹].

$$f(v_k) = \frac{1 - \exp(-av_k)}{1 + \exp(-av_k)} \quad (۳ - ۱۶)$$

$$v_k = \sum_{j=1}^p w_{kj} + w_{k0} \quad (۳ - ۱۷)$$


$$y_k = f(v_k) \quad (۳ - ۱۸)$$

a مقدار ثابتی است که یک در نظر می‌گیریم. شبکه چند لایه جلو رونده از لایه ورودی، تعدادی لایه پنهان و لایه خروجی تشکیل شده است. مطابق شکل (۳-۹) خروجی هر نرون به ورودی تمام نرون‌ها در لایه بعدی متصل است [۹].

۲.۶.۳ تابع فعالسازی


شکل (۱۱-۳) شماتیک شبکه عصبی پیش رونده را نشان میدهد. ورودی‌های وزن دار از هر کدام از لایه‌های قبلی نرون ها محاسبه شده است و مطابق فرمول (۱۹-۳) جمع زده می‌شود [۲۱].

$$X = \sum_{i=0}^n w_i I_i \quad (۱۹-۳)$$




شکل (۱۱-۳): ساده ترین حالت شبکه عصبی جلو رونده [۲۱].

و سپس این مجموع از تابع فعالسازی $t(x)$ عبور می‌کند. انتخاب تابع فعالسازی تأثیر زیادی روی نرخ کلی یادگیری و دقت الگوریتم آموزش شبکه استفاده شده دارد. انواع زیادی از توابع فعالسازی قابل قبول وجود دارد که تابع sigmoid یکی از رایج ترین‌هاست. تابع فعالسازی sigmoid در شکل (۱۲-۳) نشان داده شده است. این تابع محدودیتی روی مجموع x بین دو مقدار صفر و یک ایجاد می‌کند. تابع sigmoid به این علت در طبقه بندی داده‌ها استفاده می‌شود زیرا به عنوان مرحله عمل می‌کند که تابع هموار و قابل تشخیص باقی می‌ماند.



شکل (۱۲-۳): تابع فعالسازی sigmoid [۲۱].

مطابق شکل (۳-۱۳) تابع فعالسازی دیگری که بیشتر اوقات برای نگاشت تابعی که به عنوان یک تابع خطی شناخته می‌شود، استفاده می‌شود، تابع خطی است.



شکل (۳-۱۳): تابع فعالسازی خطی [۲۱].

۷.۳ جمع بندی

در این فصل به بررسی مسائل تئوری مورد نیاز در این پایان نامه پرداخته شد تا آشنایی با چگونگی روند کار ایجاد گردد و در ادامه به چگونگی به کار بردن این مسائل در روش پیشنهادی پرداخته شده و نتایج حاصل از آن مورد تجزیه و تحلیل قرار گرفته است.

فصل چهارم: روش پیشنهادی

۱.۴) پیشگفتار

با توجه به سوابق پژوهش در زمینه تشخیص نوع هواپیما که در فصل دو ارائه شد در این پایان نامه تلاش بر آن بوده تا تکنیک‌های به کار گرفته شده در روش‌های قبلی برای استخراج ویژگی و طبقه بندی بررسی شوند و با اضافه کردن نویز با سطوح مختلف میزان مقاومت آن‌ها در برابر نویز سنجیده شود و در نهایت بهترین روش‌ها با کمترین درصد خطا معرفی شوند. با توجه به نتایج بدست آمده و مقایسه‌ی عملکرد هر کدام از روش‌های استخراج ویژگی، روشی برای بهبود عملکرد طبقه‌بندی سیستم پیشنهاد شده و در نهایت با تحلیل روش‌های ارائه شده، مزیت و معایب هر کدام از روش‌ها شرح داده شده است.

۲.۴) روش تشخیص و طبقه‌بندی انواع هواپیما

روش ارائه شده در این پایان نامه دارای چندین قسمت است:

۱- روش‌های استخراج ویژگی به کار برده شده شامل ضرایب کپستروم حقیقی، ضرایب کپستروم فرکانس مل (MFCC)، فرکانس طیفی خط (LSF)، ضرایب پیشگوی خطی (LPC) با در نظر گرفتن دو مقدار برای ضریب P و بررسی نتایج حاصل از آن در دو حالت $P=10$ و $P=16$ و انرژی تبدیل موجک در دو حالت یکی با سطوح تجزیه مختلف و یکی با موجک‌های مختلف است.

۲- با اضافه کردن نویز گوسی سفید با نسبت سیگنال به نویز (SNR)، ۳ و ۹ دسی بل به سیگنال، عملکرد روش‌های استخراج ویژگی در برابر نویز بررسی می‌شود.

۳- در این پایان نامه از شبکه عصبی مصنوعی (ANN) برای ساخت طبقه بند و شناسایی در سیستم تشخیص صدا بخاطر قدرت پردازش و سرعت آن استفاده شده است.

نکته قابل توجه در این قسمت این است که در شبکه عصبی ممکن است تعداد زیادی خطای کوچک با مینیمم کردن مقدار خطاها اتفاق بیافتد در واقع شبکه عصبی از خطا با گام بزرگ پرهیز می‌کند. اما


در مسئله طبقه بندی آن چیزی که اهمیت دارد تعداد خطاهاست. بنابراین یکی از کارهایی که می-توان انجام داد تا تمام طبقات کلاس‌ها هم ارزش شوند کد کردن خروجی است. بنابراین در این پایان-نامه که چهار کلاس مختلف داریم خروجی را توسط رابطه‌ی (۴ - ۱) تعریف می‌کنیم.

$$y=\{0,1,2,3\} \rightarrow \begin{cases} y=0 & y=[1\ 0\ 0\ 0] \\ y=1 & y=[0\ 1\ 0\ 0] \\ y=2 & y=[0\ 0\ 1\ 0] \\ y=3 & y=[0\ 0\ 0\ 1] \end{cases} \quad (۴ - ۱)$$

با این کار شبکه عصبی تمام کلاس‌ها با ارزش مساوی دچار خطا می‌شوند و شبکه عصبی برای آن‌ها تمایز قائل نمی‌شود. این روش تعداد خروجی‌ها را افزایش می‌دهد و تعداد وزن‌ها را بالا می‌برد بنابراین برای این حالت به داده‌های بیشتری نیاز داریم. در روش‌های قبلی برای کد کردن خروجی از روش تصمیم‌گیری درختی و کد کردن باینری استفاده شده است. روش تصمیم‌گیری درختی به خاطر اینکه دو به دو به مقایسه کلاس‌ها می‌پردازد برای تعداد کلاس‌های بیشتر از دوتا زمان بیشتری می‌برد و خطاهای بالاتری در طبقه‌بندی دارد. همچنین این روش نسبت به روش باینری این مزیت را دارد که بعد از طبقه بندی داده مربوط به طبقات مختلف روی قطر اصلی ماتریس قرار می‌گیرند. بنابراین تشخیص خطا در آن به نسبت ساده‌تر است.

۴- در نهایت روشی ارائه شده که نرخ طبقه‌بندی را افزایش دهد و عملکرد آن را بهبود دهد. در این روش با توجه به اینکه حضور نویز پس زمینه در سیگنال می‌تواند سبب تخریب عملکرد تشخیص شود برای مقابله با اثر نویز قبل از مرحله استخراج ویژگی با استفاده از تبدیل موجک سیگنال صوتی مورد نظر در دو سطح تجزیه شده است و پس از آن با استفاده از سیگنال تقریب بدست آمده مراحل استخراج ویژگی و طبقه بندی انجام شده است. در واقع در تبدیل موجک با تقسیم سیگنال به دو قسمت سیگنال تقریب و سیگنال جزئیات، جداسازی نویز از سیگنال می‌شود. پس از آن برای بهبود عملکرد طبقه بند از ترکیب دو روش استخراج ویژگی ضرایب کپستروم و LSF، به عنوان روش استخراج ویژگی جدید استفاده شده است.


در بلوک دیاگرام شکل (۴-۱) روند مراحل انجام کار نشان داده شده است.




شکل (۴-۱): بلوک دیاگرام روش پیشنهادی.

۳.۴ پایگاه داده مورد استفاده در این پایان نامه

پایگاه داده شامل ۴۹ سیگنال صوتی مختلف از انواع مختلف هواپیما است که در بازه زمانی چندثانیه تا ۵ دقیقه ضبط شده‌اند و شامل ۱۸ سیگنال صوتی هلی کوپتر، ۱۹ سیگنال صوتی جت، ۷ سیگنال صوتی هواپیمای تک موتوره و ۵ سیگنال صوتی هواپیمای چند موتوره می‌شود. این داده‌ها از سایت www.freesound.org گرفته شده است. به عنوان مثال سیگنال صوتی شکل (۴-۲) متعلق به یک هواپیمای بزرگ بوئینگ است.



شکل (۴-۲): سیگنال اصلی.




شکل (۴-۳): اسپکتروگرام سیگنال اصلی.


شکل (۴-۳) اسپکتروگرام سیگنال صوتی هواپیمای بوئینگ را نشان می‌دهد. همانطور که در شکل (۴-۳) مشخص است اسپکتروگرام نمایشی از رابطه بین زمان-فرکانس را به ما می‌دهد که در آن رنگ‌ها نشان‌دهنده میزان انرژی و یا فرمونت‌های صوتی در چارچوب زمان است. هر چه رنگ روشن‌تر باشد بیان‌کننده میزان انرژی بیشتر است. همچنین اسپکتروگرام باند پهن نمایش داده شده پهنای باند زیادی دارد و بازه فرکانسی بیشتری در واحد زمان از آن عبور می‌کند به همین خاطر رزولوشن زمانی نسبت به رزولوشن فرکانسی بهتر است.

۴.۴) پیش پردازش

این مرحله برخی اطلاعات نامناسب را که بر اثر نویزهای شدید محیط به وجود می آید، حذف می کند و سیگنال یکنواخت می شود. همچنین برای بررسی این سیگنال نیاز است سیگنال ایستا در نظر گرفته شود به همین خاطر سیگنال در پنجره ای هموار با طول محدود مانند پنجره همینگ ضرب شود . با توجه به مسائل عنوان شده قبل از استخراج ویژگی از سیگنال صوتی مرحله پیش پردازش قرارداد که شامل اعمال فیلتر پیش تأکید و فریم بندی سیگنال و اعمال پنجره همینگ با هم پوشانی ۵۰ درصد است. شکل (۴-۴) و (۵-۴) نتایج اعمال فیلتر پیش تأکید و پنجره همینگ را بر سیگنال اصلی نشان می دهد.



شکل (۴-۴): سیگنال اصلی پس از پیش پردازش



شکل (۵-۴): اعمال پنجره همینگ روی سیگنال فریم شده

۵.۴ شبیه سازی

۱.۵.۴ آزمایش اول: تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی LPC

ضرایب پیشگوی خطی (LPC) یکی از قویترین روش‌های آنالیز صدا هستند که تخمین‌های بسیار دقیق از پارامترهای صدا را فراهم می‌کند. در واقع LPC را می‌توان به عنوان نماینده پارامتری از طیف هواپیما در نظر گرفت. در این پایان‌نامه بردار ویژگی LPC در دو حالت ۱۶ و ۱۰ نقطه‌ای بررسی شده است. مجموعه آموزش داده‌ها شامل ۴۹۰۰ فریم (۱۰۰ فریم برای هر هواپیما) است. که مرحله آموزش شامل ۳۴۳۰ فریم و مرحله آزمایش شامل ۱۴۷۰ فریم است. تابع فعالساز $\tan$ -sigmoidal در لایه‌های پنهان و لایه خروجی شبکه عصبی استفاده شده است. نرون‌های ورودی برابر با ماتریس ویژگی‌های ورودی است که در اینجا برای مجموعه آموزش دو ماتریس 10×3430 و 16×3430 و برای مجموعه آزمایش دو ماتریس 10×1470 و 16×1470 را خواهیم داشت و تعداد نرون‌های لایه پنهان ۱۰ تا است. همچنین تابع هدف خروجی بصورت $(1 \ 0 \ 0 \ 0)$ $(0 \ 1 \ 0 \ 0)$ $(0 \ 0 \ 1 \ 0)$ $(0 \ 0 \ 0 \ 1)$ تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است. بعد از هر تعداد ثابت از دوره‌های آموزشی، عملکرد طبقه‌بند برای داده‌های آزمون مورد ارزیابی قرار گرفته است. در طول

آزمایش و آموزش مقدار مجموع مربع خطا (MSE) نیز محاسبه شده و به ازای کمترین مقدار آن بهترین عملکرد را بدست آمده است. همچنین ارزیابی میزان دقت طبقه بندی توسط نرخ طبقه بندی صحیح داده‌ها (CCR) بیان می‌شود. که توسط تقسیم مجموع ماتریس درهم ریختگی طبقه‌بند به تعداد کل عناصر آن بدست می‌آید.

۲.۵.۴) آزمایش دوم: تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی MFCC

در این پایان‌نامه MFCC39 برای بدست آوردن بردار ویژگی در نظر گرفته شده‌است. با توجه به آنچه که در فصل ۳ توضیح داده شد از مجموع ۳۹ پارامتر MFCC، ۱۲ تای آن اصلی، ۱۲ تا مربوط به مشتق اول، ۱۲ تا مربوط به مشتق دوم، یکی مربوط به انرژی و یکی مربوط به مشتق اول انرژی و یکی مربوط به مشتق دوم انرژی است. باتوجه به اینکه ۴۹۰۰ فریم برای داده‌ها داریم، ماتریس ویژگی استخراج شده یک ماتریس 39×4900 خواهد بود. در واقع برای داده‌های آموزش 39×3430 و برای داده‌های آزمایش 39×1470 است. تعداد نرون‌های لایه پنهان ۱۰ تا است. همچنین تابع هدف خروجی بصورت $(0 \ 0 \ 0 \ 1)$ $(0 \ 1 \ 0 \ 0)$ $(1 \ 0 \ 0 \ 0)$ تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است.

۳.۵.۴) آزمایش سوم: تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی انرژی تبدیل موجک

تبدیل موجک بخاطر محلی‌سازی خوب مقیاس زمانی نه تنها منعکس کننده مشخصات سیگنال در حوزه فرکانس است بلکه توصیفی از حوزه زمان به ما می‌دهد. بنابراین استخراج ویژگی از طریق تبدیل موجک دارای ثبات است. فضای سیگنال تقریب و سیگنال جزئیات می‌تواند فرکانس سیگنال اصلی را وقتی اطلاعات محلی شده اند ارائه دهد. به خصوص می‌تواند فرکانسهای مختلف را ارائه دهد. در این پایان‌نامه انرژی تبدیل موجک به عنوان ویژگی در نظر گرفته شده است.

حالت اول: بررسی عملکرد انرژی تبدیل موجک در ۴ سطح تجزیه با موجک‌های

db10 و db2، HAAR(db1)

با استفاده از انرژی تبدیل موجک و سه موجک db10، HAAR(db1) و db2 نشان داده شده است. باتوجه به ۴۹۰۰ فریم و ۴ سطح تجزیه برای داده ها ، ماتریس ویژگی استخراج شده یک ماتریس ۴۹۰۰*۵ خواهد بود. در واقع ماتریس ویژگی برای داده های آموزش ۳۴۳۰*۵ و برای داده‌های آزمایش ۱۴۷۰*۵ است. تعداد نرون‌های لایه پنهان ۱۰ تا است. همچنین تابع هدف خروجی بصورت $(1 \ 0 \ 0 \ 0)$ $(0 \ 1 \ 0 \ 0)$ $(0 \ 0 \ 1 \ 0)$ $(0 \ 0 \ 0 \ 1)$ تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است.

حالت دوم: بررسی عملکرد انرژی تبدیل موجک با موجک db10 در سطوح تجزیه مختلف

باتوجه به ۴۹۰۰ فریم و سطوح تجزیه مختلف ، ماتریس ویژگی استخراج شده سه حالت مختلف دارد.

۱- مجموعه آموزش ۳۴۳۰*۳ و مجموعه آزمایش ۱۴۷۰*۳

۲- مجموعه آموزش ۳۴۳۰*۵ و مجموعه آزمایش ۱۴۷۰*۵

۳- مجموعه آموزش ۳۴۳۰*۱۱ و مجموعه آزمایش ۱۴۷۰*۱۱

تعداد نرون‌های لایه پنهان ۱۰ تا است. همچنین تابع هدف خروجی بصورت $(1 \ 0 \ 0 \ 0)$ $(0 \ 1 \ 0 \ 0)$ $(0 \ 0 \ 1 \ 0)$ $(0 \ 0 \ 0 \ 1)$ تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است.

۴.۵.۴) آزمایش چهارم: تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی LSF

ویژگی LSF با در نظر گرفتن $p=16$ بدست آمده است. همانطور که در فصل ۳ توضیح داده شد پارامترهای LSF در بردارنده‌ی اطلاعات قله‌های (فرمت‌های) طیفی فرکانس‌ها هستند و صفرهای چند جمله‌ای آن روی دایره‌ی واحد قرار می‌گیرند و ریشه‌های متقارن و نامتقارن آن پراکنده هستند. با توجه به اینکه LSF رابطه نزدیکی با فرمت‌های طیف هواپیما دارد برای اینکه وجود نویز در سیگنال باعث تار شدن این فرمت‌ها و در نتیجه آن تخریب عملکرد LSF نشود قبل از مرحله استخراج ویژگی با استفاده از موجک $db10$ و در یک سطح، سیگنال را تجزیه کرده و از سیگنال تقریب به دست آمده برای استخراج ویژگی استفاده شده است. ماتریس ویژگی استخراج شده یک ماتریس 16×2940 خواهد بود زیرا پهنای باند سیگنال نصف می‌شود و به جای ۱۰۰ فریم از هر سیگنال ۶۰ فریم از هر کدام در نظر گرفته شده است. در واقع ماتریس ویژگی برای داده‌های آموزش 16×2058 و برای داده‌های آزمایش 16×882 است. تعداد نرون‌های لایه پنهان ۱۰ تا است. همچنین تابع هدف خروجی بصورت $(1 \ 0 \ 0 \ 0)$ $(0 \ 1 \ 0 \ 0)$ $(0 \ 0 \ 1 \ 0)$ $(0 \ 0 \ 0 \ 1)$ تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است.

۵.۵.۴) آزمایش پنجم: تشخیص نوع هواپیما با استفاده از روش استخراج ویژگی Real

Cepstrum

تحلیل کپستروم یک تکنیک غیر خطی پردازش سیگنال است و همین باعث می‌شود برخی نویزهای سطح پایین سیگنال را شامل شود به همین خاطر قبل از مرحله استخراج ویژگی با استفاده از موجک $db10$ و در یک سطح، سیگنال را تجزیه کرده و از سیگنال تقریب به دست آمده برای استخراج ویژگی استفاده شده است. Real Cepstrum یا همان کپستروم حقیقی زیر مجموعه‌ای از تحلیل کپستروم است با این تفاوت که کپستروم حقیقی مقادیر حقیقی فرمت‌های طیف سیگنال را شامل می‌شود. تعداد نرون‌های لایه پنهان برای طبقه بند شبکه عصبی ۱۰ تا است. همچنین تابع هدف خروجی

بصورت (۰ ۰ ۰ ۱) (۰ ۰ ۱ ۰) (۰ ۱ ۰ ۰) (۱ ۰ ۰ ۰) تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است.

۶.۴) اضافه کردن نویز به سیگنال و بررسی عملکرد آن

از نتایج بدست آمده از فصل ۲ روشن است که حضور نویز پس زمینه در سیگنال صوتی هواپیما می‌تواند سبب تخریب غیر قابل قبولی در عملکرد سیستم تشخیص شود. بنابراین با اضافه کردن نویز پس زمینه به سیگنال با نسبت سیگنال به نویز ۹۳ دسی بل میزان قدرتمندی روش‌های استخراج ویژگی در برابر نویز سنجیده خواهد شد. نتایج حاصل از این سنجش در فصل پنجم آورده شده است.

۷.۴) نتایج شبیه سازی برای بهبود عملکرد سیستم

همانطور که گفته شد با استفاده از تبدیل موجک می‌توان نویز پس زمینه سیگنال را حذف کرد و به نتایج بهتری در طبقه‌بندی رسید. در این روش با استفاده از موجک db10 و ۲ سطح تجزیه از سیگنال، تبدیل موجک گرفته شده است. سپس با استفاده از سیگنال تقریب بدست آمده ویژگی مورد استفاده در این قسمت که ترکیبی از کپستروم حقیقی و LSF است از سیگنال تقریب استخراج شده است. ماتریس ویژگی استخراج شده یک ماتریس ۱۷*۹۸۰ خواهد بود. در واقع برای داده‌های آموزش ۱۷*۶۸۶ و برای داده‌های آزمایش ۱۷*۲۹۴ است. که ۹۸۰ تعداد فریم‌های سیگنال است و کاهش آن بخاطر نصف شدن پهنای باند سیگنال در هر مرحله از تجزیه است. تعداد نرون‌های لایه پنهان ۱۰ تا است. همچنین تابع هدف خروجی بصورت (۱ ۰ ۰ ۰) (۰ ۱ ۰ ۰) (۰ ۰ ۱ ۰) (۰ ۰ ۰ ۱) تعریف می‌شود و تعداد نرون‌های خروجی برابر با تعداد کلاس‌ها یعنی ۴ تا است.

۸.۴) جمع بندی

در این فصل ابتدا روند کار این پایان نامه و جزئیات آن معرفی شده است که شامل استخراج ویژگی - های ضرایب کپستروم حقیقی، ضرایب کپستروم فرکانس مل (MFCC)، فرکانس طیفی خط (LSF)، ضرایب پیشگوی خطی (LPC) با در نظر گرفتن دو مقدار برای ضریب P و بررسی نتایج حاصل از آن در دو حالت $P=10$ و $P=16$ و انرژی تبدیل موجک در دو حالت یکی با سطوح تجزیه مختلف و یکی با موجک های مختلف است. پس از آن با اضافه کردن نویز پس زمینه به سیگنال عملکرد هر کدام از روش های استخراج ویژگی سنجیده شده و در نهایت روشی برای بهبود عملکرد سیستم با میزان دقت بالا در طبقه بندی ارائه شد که از تبدیل موجک به عنوان حذف کننده نویز و از ترکیب کپستروم حقیقی و LSF به عنوان روش استخراج ویژگی استفاده می کند. که نتایج حاصل در فصل پنجم آورده شده است.

فصل پنجم: نتایج و پیشنهادات

۱.۵ پیشگفتار

در این پایان نامه روش های مختلف استخراج ویژگی بررسی شده است و طبقه بندی توسط شبکه عصبی مصنوعی جلو رونده انجام شده است و مقاومت این روش ها در برابر نویز با سطوح مختلف سنجیده شده است سپس با توجه به نتایج بدست آمده روشی برای بهبود عملکرد سیستم و کاهش خطای شناسایی پیشنهاد شده است. در این فصل به ارائه نتایج حاصل از شبیه سازی و تحلیل و بحث پیرامون این نتایج پرداخته ایم.


۲.۵ نتایج شبیه سازی

۱.۲.۵ آزمایش اول: نتایج حاصل از روش استخراج ویژگی LPC

همانطور که از نتایج جدول (۱-۴) مشخص است هر چه مقدار P بیشتر باشد میزان خطای طبقه بندی کمتر است و تشخیص و طبقه بندی هواپیماها با دقت بهتری انجام شده است. زیرا با توجه به تعریف LPC با افزایش مقدار P تابع پیش بینی شده به تابع اصلی نزدیکتر خواهد بود و می تواند تقریب صحیح تری از تابع اصلی راداشته باشد. اما این افزایش مقدار ضریب P تا یک مقداری می تواند مفید باشد و از یک مقداری به بعد باعث تضعیف عملکرد سیستم می شود. همانطور که از نتایج جدول (۱-۴) مشخص است در $P=20$ عملکرد سیستم تضعیف شده است و با توجه به شکل مقدار بهینه P برای این سیستم ۱۶ است.

جدول (۵-۱): نتایج طبقه بندی با استفاده از ضرایب LPC

نتایج طبقه بندی با استفاده از ضرایب LPC			انواع هواپیما	
P=20	P=16	P=10		
۴۸/۶۶	۶۴/۲۸	۵۲/۵۳	هلی کوپتر	
۵/۴۵	۸۴/۸۸	۸۶/۳۸	جت	
۷۵/۵۶	۲۸/۹۴	۲۶/۴۹	تک موتوره	
۰/۷۴۹۵	۱۲/۲۶	۶/۳۳	چند موتوره	
۰/۵۶۰۱	۰/۲۳۲۲	۰/۴۳۲۲	MSE	معیار سنجش خطا
۳۰/۸۱	۵۹/۴۵	۵۴/۸۰	CCR	نرخ طبقه بندی صحیح داده‌ها



شکل (۱-۵): مقایسه نرخ طبقه بندی داده ها در ضرایب p مختلف.

ConfMat_ts =

255	0	269	0
86	31	439	12
45	4	167	5
10	0	147	0

شکل (۲-۵): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب LPC.

۲.۲.۵ آزمایش دوم: نتایج حاصل از روش استخراج ویژگی MFCC

جدول (۱-۴) نتایج طبقه بندی با استفاده از روش استخراج ویژگی MFCC را نشان می دهد. با توجه به نتایج حاصل از شبیه سازی ویژگی MFCC عملکرد نسبتاً خوبی در طبقه بندی از خود نشان داده است.

جدول (۵-۲): نتایج طبقه‌بندی با استفاده از MFCC

انواع هواپیما	MFCC
هلی کوپتر	۷۷/۷۳
جت	۵۶/۹۷
تک موتوره	۳۹/۷۵
چند موتوره	۴۱/۳۷
معیار سنجش خطا	MSE
نرخ طبقه بندی صحیح داده ها	CCR
	۰/۱۶۵۷
	۶۰/۹۹

۳.۲.۵) آزمایش سوم: نتایج حاصل از روش استخراج ویژگی انرژی تبدیل موجک

حالت اول: نتایج حاصل از روش انرژی تبدیل موجک در ۴ سطح تجزیه با موجک‌های

db10 و db2, HAAR

در جدول (۴-۳) نتایج طبقه بندی با استفاده از انرژی تبدیل موجک و سه موجک db2, HAAR و db10 نشان داده شده است. همانطور که از نتایج شبیه سازی در جدول (۴-۳) مشخص است با افزایش مرتبه N در خانواده‌ی dbN خطا کمتر شده و میزان دقت طبقه بندی و نرخ طبقه بندی صحیح داده ها بیشتر می‌شود. در واقع در موجک HAAR توابع مقیاس و موجک‌ها ناپیوسته هستند ولی با افزایش N رفتار توابع موجک و مقیاس بهبود می‌یابد و پیوسته می‌شوند به همین خاطر عملکرد بهتری دارند.

جدول (۵-۳): نتایج طبقه بندی با استفاده از انرژی تبدیل موجک (حالت اول).

نتایج حاصل از طبقه بندی با استفاده از انرژی تبدیل موجک در سطح تجزیه ۴			انواع هواپیما	
db10	db2	HAAR		
۹۵/۵۲	۹۴/۵۸	۸۴/۳۲	هلی کوپتر	
۷۴/۹۷	۶۷/۸۱	۶۰/۶	جت	
۶۲/۵۶	۵۰/۷۸	۴۷/۹۶	تک موتوره	
۷۹/۲۶	۶۵/۵۴	۶۸/۳۵	چند موتوره	
۰/۰۸۴۴	۰/۰۹	۰/۱۲۲۵	MSE	معیارهای سنجش
۷۹/۰۴	۷۵/۲۰	۶۸/۹۱	CCR	

حالت دوم: نتایج حاصل از روش انرژی تبدیل موجک با موجک db10 در سطوح تجزیه

مختلف

جدول (۴-۴) نتایج طبقه بندی با استفاده از انرژی تبدیل موجک در سطوح تجزیه مختلف را نشان

می دهد.

همانطور که از نتایج شبیه سازی در جدول (۴-۴) مشخص است هر چه سطح تجزیه سیگنال بالاتر

می رود جزئیات سیگنال تجزیه شده بیشتر خواهد شد در واقع نویز با سطح انرژی بالاتر توسط تبدیل

موجک از سیگنال اصلی جدا می‌شود و انرژی تبدیل موجک شامل انرژی سیگنال تقریب و انرژی سیگنال جزئیات به طور جداگانه خواهد بود. بنابراین در سطوح تجزیه بالاتر قویتر از دیگر حالت‌ها عمل می‌کند.

جدول (۴-۵): نتایج طبقه بندی با استفاده از انرژی تبدیل موجک (حالت دوم).

نتایج حاصل از طبقه بندی با استفاده از انرژی تبدیل موجک و db10			انواع هواپیما	
۱۰ سطح تجزیه	۴ سطح تجزیه	۲ سطح تجزیه		
۹۳/۵۴	۹۴/۵۸	۸۸/۸۳	هلی کوپتر	
۶۶/۹۵	۶۷/۸۱	۵۵/۲۵	جت	
۷۳/۴۳	۵۰/۷۸	۴۹/۴۱	تک موتوره	
۸۲/۴۳	۶۵/۵۴	۶۸/۹۱	چند موتوره	
۰/۰۷۹	۰/۰۹	۰/۱۰۹۸	MSE	معیارهای سنجش خطا
۸۰/۲۷	۷۵/۲۰	۶۸/۹۱	CCR	

۴.۲.۵) آزمایش چهارم نتایج حاصل از روش استخراج ویژگی LSF

جدول (۴-۵) نتایج طبقه بندی با استفاده از روش استخراج ویژگی LSF را نشان می دهد. همانطور که از نتایج شبیه سازی در جدول (۴-۵) مشخص است ضرایب LSF عملکرد بسیار خوبی در طبقه بندی دارند و علت آن هم ارتباط نزدیک ضرایب LSF با قله های طیفی و استفاده از تبدیل موجک به عنوان یک فیلتر است. همچنین شکل ماتریس در هم ریختگی حاصل از طبقه بندی با استفاده از ضرایب LSF در داده های آزمایش نشان می دهد همانطور که قبلا اشاره شد قطر اصلی این ماتریس نشان دهنده ی ۴ کلاس تعریف شده هستند.

جدول (۵-۵): نتایج طبقه بندی با استفاده از LSF

انواع هواپیما	نتایج حاصل از طبقه بندی با استفاده از LSF
هلی کوپتر	۹۱
جت	۹۲/۰۹
تک موتوره	۷۳/۲۸
چند موتوره	۸۷/۶۲
معیار سنجش خطا	MSE ۰/۰۶۳۱
نرخ طبقه بندی صحیح داده ها	CCR ۸۸/۴۳

ConfMat_ts =

273	17	4	6
2	326	1	25
9	3	96	23
1	10	1	85

شکل (۳-۵): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب LSF.

۵.۲.۵) آزمایش پنجم: نتایج حاصل از روش استخراج ویژگی Real Cepstrum

جدول (۴-۶) نتایج طبقه بندی با استفاده از روش استخراج ویژگی Real Cepstrum را نشان می‌دهد. با توجه به نتایج بدست آمده در جدول (۴-۶) مانند نتایج خوبی را نشان می‌دهد که علت آن استفاده از تبدیل موجک به عنوان یک فیلتر برای سیگنال به علت وجود عملگر لگاریتمی غیر خطی است که نویزهای سطح پایین بخشی از سیگنال صوتی را شامل می‌شود. در واقع با این کار از تاثیر گذاشتن نویزهای سطح پایین بر سیگنال جلوگیری شده است. همچنین شکل ماتریس در هم ریختگی حاصل از طبقه بندی با استفاده از ضرایب LSF در داده‌های آزمایش نشان می‌دهد همانطور که قبلاً اشاره شد قطر اصلی این ماتریس نشان دهنده‌ی ۴ کلاس تعریف شده هستند.

جدول (۵-۶): نتایج طبقه بندی با استفاده از Real Cepstrum.

انواع هواپیما	نتایج حاصل از طبقه بندی با استفاده از Real Cepstrum
هلی کوپتر	۸۴/۷۷
جت	۷۷/۸۱
تک موتوره	۳۴/۸۸
چند موتوره	۹۷/۵
معیار سنجش خطا	MSE ۰/۱۳۶۷
نرخ طبقه بندی صحیح داده ها	CCR ۷۵/۹۶

ConfMat_ts =

284	21	18	12
28	263	6	41
27	8	45	49
1	1	0	78

شکل (۵-۴): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب Real Cepstrum.

۳.۵) اضافه کردن نویز به سیگنال و بررسی عملکرد آن

۱.۳.۵) آزمایش اول: تأثیر افزودن نویز در روش استخراج ویژگی LPC با $P=10$

جدول (۷-۴) عملکرد روش استخراج ویژگی LPC را در شرایط نویزی به همراه دو نویز با SNR های مختلف نشان می‌دهد. هر چه مقدار SNR کمتر باشد به این معنی است که میزان نویز آن بیشتر است. با توجه به نتایج بدست آمده از جدول (۷-۴) مشاهده می‌شود که هر چند مقداری تخریب در نتایج مشهود است اما LPC عملکرد خوبی و مقاومت خوبی در برابر نویز دارد. دلیل تضعیف عملکرد این است که با اضافه شدن نویز به سیگنال فرمونت‌های (قله‌های) طیفی تا حدی تخریب می‌شوند و قله‌ها و دره‌های طیفی سیگنال تار شده و تشخیص آن‌ها دشوار می‌شود. همچنین نتایج بدست آمده نشان می‌دهد که هر چه مقدار SNR بیشتر شود عملکرد سیگنال بهتر و میزان خطا کمتر می‌شود.

جدول (۵-۷): نتایج طبقه بندی سیگنال نویزی با استفاده از LPC , $P=10$.

انواع هواپیما		نتایج حاصل از طبقه بندی با استفاده از ضرایب LPC و $P=10$	
		SNR=9dB	SNR=3dB
هلی کوپتر		۷۸/۳۵	۷۲/۷۸
جت		۴۵/۸۱	۳۶/۲۵
تک موتوره		۲۹/۴۳	۸/۹۷
چند موتوره		۵۲/۷۰	۶۲/۲۲
معیار سنجش خطا	MSE	۰/۱۴۱۱	۰/۱۶۱۶
نرخ طبقه بندی صحیح داده- ها	CCR	۵۶/۴۵	۴۹/۷۲

۲.۳.۵) آزمایش دوم: تأثیر افزودن نویز در روش استخراج ویژگی LPC با $P=16$

جدول (۴-۸) عملکرد روش استخراج ویژگی LPC را در شرایط نویزی به همراه دو نویز با SNR های مختلف را نشان می دهد. در این حالت به علت بیشتر بودن ضریب P عملکرد LPC در شرایط نویزی نسبتاً بهتر از حالت قبل است و مقاومت خوبی در برابر نویز دارد.

جدول (۵-۸): نتایج طبقه بندی سیگنال نویزی با استفاده از LPC , $P=10$.

انواع هواپیما		نتایج حاصل از طبقه بندی با استفاده از ضرایب $P=16$ و LPC	
		SNR=9dB	SNR=3dB
هلی کوپتر		۱۸/۰۶	۹۰/۵۲
جت		۹۰/۲۱	۲۳/۰۴
تک موتوره		۳۹/۳۹	۱۲/۶۹
چند موتوره		۲۱/۳۲	۴۶/۲
معیار سنجش خطا	MSE	۰/۱۴۴۲	۰/۱۸۹۸
نرخ طبقه بندی صحیح داده‌ها	CCR	۴۷/۸۰	۴۶/۷۳

۳.۳.۵) آزمایش سوم: تأثیر افزودن نویز در روش استخراج ویژگی MFCC

جدول (۴-۹) نتایج طبقه بندی سیگنال نویزی با استفاده از روش استخراج ویژگی MFCC را نشان می‌دهد. اضافه شدن نویز به سیگنال تغییر قابل توجهی در عملکرد سیستم ایجاد کرده است. و کاملاً مشهود است که روش استخراج ویژگی MFCC مقاومت خوبی در برابر نویز ندارد. همچنین مشخص است که با افزایش SNR عملکرد سیستم بهبود یافته است.

جدول (۵-۹): نتایج طبقه بندی سیگنال نویزی با استفاده از MFCC.

انواع هواپیما		نتایج حاصل از طبقه بندی با استفاده از MFCC	
		SNR=9dB	SNR=3dB
هلی کوپتر		۷۲/۷۸	۴۰/۶۸
جت		۳۶/۲۵	۵۶/۸۲
تک موتوره		۸/۹۷	۵/۸۵
چند موتوره		۶۲/۲۲	۰
معیار سنجش خطا	MSE	۰/۱۶۱۶	۰/۲۱۵۴
نرخ طبقه بندی صحیح داده ها	CCR	۴۹/۷۲	۳۵/۴۱

۴.۳.۵ آزمایش چهارم: تأثیر افزودن نویز در روش استخراج ویژگی Real Cepstrum

جدول (۴-۱۰) مشخص است که در SNR=3dB تخریب قابل ملاحظه‌ای در عملکرد سیستم رخ داده است اما با افزایش مقدار SNR بهبود یافته است. در واقع این تخریب شدید عملکرد به این علت است که کپستروم حقیقی از عملیات لگاریتم غیرخطی استفاده می‌کند که این امر باعث می‌شود نویز سطح پایین بخشی از طیف صوتی را شامل شود و با اضافه شدن نویز با سطوح سیگنال به نویز مختلف و افزایش مقدار نویز سیگنال عملکرد سیستم تشخیص تضعیف می‌شود. همچنین شکل‌های ماتریس در هم ریختگی حاصل از طبقه بندی در حالت نویزی در داده‌های آزمایش نشان را می‌دهد همانطور که قبلاً اشاره شد قطر اصلی این ماتریس نشان دهنده‌ی چهارکلاس تعریف شده هستند.

جدول (۵-۱۰): نتایج طبقه بندی سیگنال نویزی با استفاده از Real Cepstrum.

انواع هواپیما		نتایج حاصل از طبقه بندی با استفاده از Real Cepstrum	
		SNR=9dB	SNR=3dB
هلی کوپتر		۶۱/۹۵	۵۷/۷۳
جت		۳۹/۲۴	۵۱/۰۵
تک موتوره		۲۲/۷۲	۱۰/۴۴
چند موتوره		۶۰/۴۶	۱۳/۹۲
معیار سنجش خطا	MSE	۰/۱۷۷۷	۰/۲۱۰۹
نرخ طبقه بندی صحیح داده ها	CCR	۵۶/۱۲	۴۴/۱۰

ConfMat_ts =

194	135	0	7
134	170	9	20
49	71	14	0
31	28	9	11

شکل (۵-۵): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی Real Cepstrum با نویز ۳ dB.

ConfMat_ts =

259	33	13	15
192	135	5	12
76	15	30	11
30	4	0	52

شکل (۵-۶): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی Real Cepstrum با نویز ۹ dB.

۵.۳.۵) آزمایش پنجم: تأثیر افزودن نویز در روش استخراج ویژگی LSF

جدول (۴-۱۱) نتایج طبقه بندی سیگنال نویزی با استفاده از روش استخراج ویژگی LSF را نشان می‌دهد. با توجه به نتایج بدست آمده تخریب در عملکرد سیستم در هر دو مقدار SNR وجود دارد. در واقع در روش استخراج ویژگی به وسیله LSF به خاطر تار شدن قله‌ها و دره‌های طیفی در شرایط نویزی تفکیک بین سیگنال‌ها دشوار خواهد بود. اما با این حال LSF مقاومت خوبی در برابر نویز از خود نشان داده است. همچنین شکل‌های ماتریس در هم ریختگی حاصل از طبقه بندی با استفاده از ضرایب LSF در داده‌های نویزی آزمایش را نشان می‌دهد همانطور که قبلاً اشاره شد قطر اصلی این ماتریس نشان دهنده‌ی ۴ کلاس تعریف شده هستند.

جدول (۵-۱۱): نتایج طبقه بندی سیگنال نویزی با استفاده از LSF.

انواع هواپیما		نتایج حاصل از طبقه بندی با استفاده از LSF	
		SNR=9dB	SNR=3dB
هلی کوپتر		۷۰/۸۸	۶۵/۳۶
جت		۵۸/۲۵	۶۱/۹
تک موتوره		۴۳/۳۳	۳/۵۹
چند موتوره		۶۵/۰۹	۴۸
معیار سنجش خطا	MSE	۰/۱۳۴۷	۰/۱۷۸۴
نرخ طبقه بندی صحیح داده ها	CCR	۶۱/۴۵	۵۲/۸۳

ConfMat_ts =

217	105	3	7
121	208	4	3
78	45	5	11
17	19	3	36

شکل (۵-۷): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی LSF با نویز ۳ dB.

ConfMat_ts =

224	60	29	3
123	194	16	0
57	12	55	3
14	10	13	69

شکل (۵-۸): ماتریس در هم ریختگی حاصل از طبقه بندی توسط ضرایب نویزی LSF با نویز ۹ dB.

۵.۳.۶) آزمایش ششم: تأثیر افزودن نویز در روش استخراج ویژگی از انرژی تبدیل موجک در ۴ سطح تجزیه

جدول (۴-۱۲) نتایج طبقه بندی سیگنال نویزی با استفاده از انرژی تبدیل موجک و موجک‌های HAAR، db2 و db10 در ۴ سطح تجزیه را نشان می‌دهد. که تبدیل موجک به علت تفکیک سیگنال در برابر افزوده شدن نویز به سیگنال مقاوم است و عملکرد خوبی از خود نشان می‌دهد. همانطور که قبلاً گفته شد هرچه مرتبه N در خانواده موجک dbN بیشتر باشد، عملکرد سیگنال هم بهتر خواهد بود همچنین می‌توان دریافت که در SNR=3dB سیستم به علت شدید بودن مقدار نویز، عملکرد ضعیفتری دارد.

جدول (۵-۱۲): نتایج طبقه بندی سیگنال نویزی با استفاده از انرژی تبدیل موجک در ۴ سطح تجزیه.

انواع هواپیما						نتایج حاصل از طبقه بندی با استفاده از انرژی تبدیل موجک در ۴ سطح تجزیه	
		HAAR		DB2		DB10	
		SNR=9dB	SNR=3dB	SNR=9dB	SNR=3dB	SNR=9dB	SNR=3dB
هلی کوپتر		۶۱/۵۱	۶۳/۳۲	۷۸/۳۳	۹۴/۴۹	۸۴/۵۹	۶۸/۲۲
جت		۴۷/۶۰	۳۳/۵۲	۲۴/۵۴	۲۱/۰۹	۲۵/۵۸	۲۸/۳۷
تک موتوره		۱۴/۲۲	۶/۴۹	۶/۲۷	۳۴/۹۰	۲۲/۶۵	۵۳/۱۷
چند موتوره		۴۴/۳۷	۳۶/۹۱	۴۳/۳۹	۶۳/۵۲	۴۷/۲۹	۴۸/۶۳
معیارها ی سنجش	MSE	۰/۱۶۴۱	۰/۱۷۴۳	۰/۱۶۶۹	۰/۱۴۱۶	۰/۱۴۸۱	۰/۱۷۱۹
	CCR	۴۷/۶۸	۴۰/۹۵	۴۴/۰۱	۵۶/۱۹	۵۲/۲۹	۵۱/۳۱

۷.۳.۵) آزمایش هفتم: تأثیر افزودن نویز در روش استخراج ویژگی از انرژی تبدیل موجک و با استفاده از موجک db10

جدول (۴-۱۳) نتایج طبقه بندی سیگنال نویزی با استفاده از انرژی تبدیل موجک و موجک db10 را نشان می‌دهد. با توجه به نتایج بدست آمده تبدیل موجک در سطوح مختلف حتی در پایین‌ترین سطوح نیز عملکرد قابل قبولی دارد و در برابر نویز مقاوم است. زیرا در روش تبدیل موجک با تجزیه سیگنال به سطوح مختلف قسمت‌های نویزی و با انرژی بالا از قسمت‌های فرکانس پایین سیگنال جدا می‌شود. که همین امر خود باعث بهبود عملکرد سیستم در حالت نویزی می‌شود.

جدول (۵-۱۳): نتایج طبقه بندی سیگنال نویزی با استفاده از انرژی تبدیل موجک و db10.

نتایج حاصل از طبقه بندی با استفاده از انرژی تبدیل موجک و dB10						انواع هواپیما	
۱۰ سطح تجزیه		۴ سطح تجزیه		۲ سطح تجزیه			
SNR=9 dB	SNR=3dB	SNR=9dB	SNR=3dB	SNR=9dB	SNR=3dB		
۸۷/۱۴	۷۰/۷۷	۶۸/۲۲	۸۴/۵۹	۷۰/۳۵	۷۷/۷۹	هلی کوپتر	
۵۷/۰۷	۶۳/۱۵	۲۸/۳۷	۲۵/۵۸	۵۱/۳۴	۲۴/۵۴	جت	
۶۹/۱۱	۷۹/۵۶	۵۳/۱۷	۲۲/۶۵	۲۳/۹۱	۸/۶۲	تک موتوره	
۶۱/۱۵	۵۸/۷۸	۴۸/۶۳	۴۵/۲۹	۹۴/۲۰	۴۳/۳۹	چند موتوره	
۰/۰۹۷۴	۰/۱۰۶۴	۰/۱۷۱۹	۰/۱۴۸۱	۰/۱۵۲۳	۰/۱۷۲۸	MSE	معیارهای سنجش
۷۱/۶۳	۶۸/۳۳	۵۱/۳۱	۵۲/۲۹	۵۱/۳۶	۴۱/۴۹	CCR	

۴.۵) نتایج شبیه سازی برای بهبود عملکرد سیستم

همانطور که از نتایج بدست آمده مشخص است ضرایب کپستروم حقیقی و ضرایب LSF عملکرد قابل قبولی در مقایسه با روش‌های دیگر داشته اند بنابراین با ترکیب این دو روش و استفاده از تبدیل موجک به عنوان یک فیلتر برای حذف نویز می‌توان به نتایج بسیار خوبی رسید. اما باید به این نکته توجه داشت که در تبدیل موجک با تجزیه سیگنال پهنای باند نصف می‌شود و با افزایش تعداد سطوح تجزیه پهنای باند سیگنال کمتر می‌شود پس در استفاده از تبدیل موجک این محدودیت وجود دارد. با توجه به نتایج بدست آمده از جدول (۴-۱۴) و مقایسه آن با نتایج جداول (۴-۱۰) و (۴-۱۱) بهبود قابل توجهی در عملکرد سیستم مشاهده می‌شود.


جدول (۵-۱۴): نتایج طبقه بندی با استفاده از LSF+Real Cepstrum.

LSF+ Real Cepstrum	انواع هواپیما	
۹۷/۸۹	هلی کوپتر	
۹۲/۲۴	جت	
۸۴/۲۱	تک موتوره	
۸۳/۳۳	چند موتوره	
۰/۰۴۵۱	MSE	معیار سنجش خطا
۹۳/۱۱	CCR	نرخ طبقه بندی صحیح داده ها


۵.۵) نتیجه گیری کلی

در فصل یک این پایان نامه به بیان مقدمات و اهداف این پایان نامه پرداخته شد. و پس از آن در فصل دو به مرور اجمالی برخی از کارهای گذشته به همراه نتایج آن پرداخته شده تا آشنایی با روش ها و نتایج و یا کم و کاستی های آن ها خط مشی برای ادامه مسیر و بهبود بخشی به نتایج و روش ها باشد. در فصل سه مبانی نظری مورد نیاز برای فهم بهتر روش پیشنهادی و طبقه بند مورد استفاده در این پایان نامه ارائه شد. و در نهایت در فصل چهار روش پیشنهادی، مراحل مختلف آن و نتایج حاصل از آن ارائه شد و با توجه به نتایج بدست آمده با تبدیل موجک گرفتن از سیگنال جهت حذف نویز و استخراج ویژگی LSF+Real Cepstrum از سیگنال تقریب بدست آمده سعی شد تا نتایج طبقه بندی بهبود یابد. در شکل های (۱-۵)، (۲-۵)، (۳-۵) و (۴-۵) نتایج بین روش های مختلف استخراج ویژگی و روش پیشنهادی که مبتنی بر اعمال تبدیل موجک جهت حذف نویز سیگنال و استخراج ویژگی LSF+Real Cepstrum از سیگنال تقریب بدست آمده مقایسه شده است. با توجه به نتایج بدست آمده از فصل چهارم تبدیل موجک در کاهش اثر نویز و بهبود عملکرد سیستم و هم در استخراج ویژگی بهترین نتایج را ارائه می دهد. همچنین روش های استخراج ویژگی LSF و Real Cepstrum نیز نتایج نسبتاً خوبی را ارائه می دهند.


با توجه به نمودارهای (۱-۵) تا (۴-۵) روش پیشنهادی بهترین نتایج را به نسبت دیگر روش ها دارد. علت آن نیز استفاده از تبدیل موجک به عنوان یک فیلتر پیش پردازش روی سیگنال هاست. همچنین زمانی که تبدیل موجک سیگنال تقریب را از سیگنال جزئیات جدا می کند تعداد نمونه های ویژگی کمتر خواهد شد و باعث افزایش سرعت پردازش سیگنال می شود.



شکل (۵-۹): مقايسه نتايج روش پيشنهادي و LPC



شکل (۵-۱۰): مقايسه نتايج روش پيشنهادي و MFCC و LSF و Real Cepstrum




شکل (۵-۱۱): مقایسه نتایج روش پیشنهادی و انرژی تبدیل موجک با موجک‌های مختلف



شکل (۵-۱۲): مقایسه نتایج روش پیشنهادی و انرژی تبدیل موجک با سطوح تجزیه مختلف

۶.۵ مقایسه با کارهای گذشته


در این قسمت روش پیشنهادی با مراجع [۷] و [۱۳] مقایسه شده است.



شکل (۵-۱۳): روش پیشنهادی



شکل (۵-۱۴): مرجع [۷]



شکل (۵-۱۵): مرجع [۱۳]

۷.۵) پیشنهادات برای کارهای آینده

یکی از تأثیر گذارترین مسائل در امر پردازش تأثیر نویز پس زمینه و حذف آن از سیگنال است. بنابراین با توجه به کمبود داده‌های با کیفیت در این زمینه یکی از کارهایی که میتوان در جهت بهبود نتایج انجام داد ضبط سیگنال‌های صوتی در بهترین شرایط محیطی است. همچنین اگر این داده‌ها به انواع دیگر هواپیماها بسط داده شود، می‌توان طبقه‌بندی را با وجود کلاس‌های بیشتری انجام داد. همچنین استفاده از تصمیم‌گیر باینری در خروجی شبکه عصبی ساختار شبکه را به شدت ساده می‌کند. اما در بسیاری از موارد شبکه را مجبور می‌کند به اشتباه یک خروجی را به عنوان تصمیم‌گیر پیش فرض در نظر بگیرد. این پایان نامه روی طبقه‌بندی ویژگی‌های استخراج شده توسط شبکه عصبی جلو رونده ساده (FFANN) تمرکز کرده است. بنابراین برای کارهای بیشتر در آینده می‌توان الگوریتم‌های استخراج ویژگی بیشتر به همراه ساختار شبکه عصبی مصنوعی مانند توابع پایه شعاع (RBF) و همچنین شبکه‌های عصب-فازی را بررسی کرد.

1. S. Akhtar, M. Elshafei-Abmed and M.S. Ahmed, (2001) " Detection of helicopters using neural nets." *IEEE Transactions on instrumentation and measurement*. **Vol 50, Issue. 3, pp.749-756.**
2. Sutin. A and Salloum. H and Sedunov. A, (2013) " Acoustic detection, tracking and classification of low flying aircraft.", IEEE International Conference on Technologies for Homeland Security (HST), Waltham, MA, USA.
- 3.N. Sadati and A. H. Faghihi . (2006)" Neural Networks in Identification of Helicopters Using Passive Sensors", IEEE International Conference on Systems, Man and Cybernetics, Taipei, Taiwan.
4. Hashem, H.F and A. Amin, (2006) " Development of Helicopters Sound Detection Systems", Proceedings of the Twenty Third National Radio Science Conference (NRSC), Menoufiya, Egypt.
۵. نوروزی م، (۱۳۸۰)، پایان‌نامه ارشد: " آشکارسازی و شناسایی خودکار بالگرد (هلی کوپتر) با استفاده از صوت"، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس.
6. N.Song, X.Dong, J.Cheng, Y.Jiao, (2012) " The Aircraft Sonic Feature Extraction Based on the Daubechies (dbN)", *Communications and Information Processing*, **Vol 289, pp. 148-15.**
7. Harlow.C and Zhu.W, (2001) " Aircraft Operations Classification System", *Journal of Air Transportation World Wide*,**Vol. 6, No. 2, pp. 47-64.**
8. Dress, W.B. and S.W. Kerckel (1994) "Wavelet-based acoustic recognition of aircraft" SPIE International Symposium on Optical Engineering and Photonics in Aerospace Sensing, Orlando, Florida , United States.
9. M.Elshafei, S.Akhtar, and M.S Ahmed (2000) ," Parametric models for helicopter identification using ANN " *IEEE Transactions on Aerospace and Electronic Systems*, **Vol. 36, Issue. 4, pp. 1242-1252.**

10. M. Elshafei and M.S. Ahmed, (1997) "Helicopter recognition using neural computation", National Computer Conference, p121-133, Dhahran.
11. R. H. Cabell, C. R. Fuller, and W. F. O'Brien, (1992) " Identification of helicopter noise using a neural network ", *American Institute of Aeronautics and Astronautics (AIAA) Journal*, **Vol. 30, No. 3** , pp. 624-630.
12. R. H. Cabell, C. R. Fuller, and W. F. O'Brien, (1993) "Neural network for the identification of measured Helicopter noise" *Journal of American Helicopter Society*, **Vol. 38, No. 3**, pp. 64-72.
13. R. G. Cabell & C. R. Fuller, (1989). "A Smart Pattern Recognition System for the Automatic Identification of Aerospace Acoustic Sources", *American Institute of Aeronautics and Astronautics Journal*, pp. 89–114.
14. Scott, E. A., Fuller, C. R., Obrien, W. F., & Cabells, R. H. (1993). "Sparse Distributed Associative Memory for the Identification of Aerospace Acoustic Sources.", *American Institute of Aeronautics and Astronautics (AIAA)* ,**Vol. 31, No. 9**, pp. 1031-1036.
15. J. D. Markel and A. H. Makhoul, (1976) "**Linear Prediction of Speech**" Vol. 5, Springer-Verlag.
16. M. Riedmiller and H. Braun, (1993) "A direct adaptive method for faster back propagation learning: The proposed algorithm", IEEE International Conference on Neural Networks (ICNN), pp. 586-591, San Francisco, CA, USA, USA.
17. S. Haykin, (1994) "**Neural Networks: A Comprehensive Foundation**", Prentice Hall, the University of Michigan.
18. G. Strang and T. Nguyen, (1996) "**Wavelets and Filter Banks**", Wellesley, MA : Wellesley-Cambridge Press.
19. N. Sugamara and F. Itakura, (1986) "Speech analysis and synthesis methods developed at ECL in NTT—from LPC to LSP ", *Speech Communication*, **Vol. 5, Issue. 2**, pp. 199-215.

20. N. Dave, (2013) " Feature extraction methods LPC, PLP and MFCC in speech recognition", *International journal for advance research in engineering and technology*, **Vol. 36, Issue. 6, pp. 1-4.**

21. K. Kirkpatrick, J. May Jr and J. Valasekz,(2013)"Aircraft System Identification Using Artificial Neural Networks ", 51st AIAA Aerospace Sciences Meeting including the New Horizons Forum and Aerospace Exposition, Texas.

Abstract

Information about the movement and type of an aircraft is usually collected by radar or electronic sensors, but this information may be unavailable due to lack of visual field. Detection and identification of the target by sound signals is very important in some cases because of geographic location, cost-effectiveness, and noise resistance. That is why another method is used to identify a target that is less disturbed by the conditions of the visual path. In this thesis the sound of an aircraft engine has been used to recognize the type of an aircraft. The audio signals received from the microphone are considered as inputs of this algorithm. In order to extract the characteristic of audio signal, the wavelet transform energy, Mel Frequency Cepstrum Coefficients (MFCC), Real Cepstrum Coefficients, linear predictive coefficients (LPCs) and spectral line frequency (LSF) have been used. Then classification of the sound signal of the aircraft is carried out for four classes of an audio data by artificial neural network classifier. To evaluate the performance of the detection system, we added noise to the signal with different signal-to-noise ratio, and compare the results with each other. Finally, we introduce a method for improving the system performance, which is used wavelet transform to eliminate the noise, and combination of LSF and real cepstrum coefficients are used as a feature extraction method. The data classification rate was %93.11 and the error rate was 0.0451.

Key words: aircraft type detection, wavelet transform, Mel Frequency Cepstrum Coefficients, Linear Predictive Coefficients, Real Cepstrum Coefficients, Line Spectral Frequency, Artificial Neural Network.



Shahrood University of Technology

Faculty of Electrical and Robotics Engineering

M. Sc. Thesis in communication Systems Engineering

**Recognition of the aircraft type based on the engine sound
using neural network**

By

Hannaneh Hadian Amrei

Supervisor

Dr. Hossein Marvi

Aug 2018