

رسالة محمد



دانشکده مهندسی برق و رباتیک

رشته مهندسی برق گرایش مخابرات

پایان نامه کارشناسی ارشد

جداسازی گفتار دو گوینده همزمان مبتنی بر ویژگی‌های مناسب

زمان - فرکانس

نگارنده :

رعنا دهقانی

استاد راهنما :

دکتر حسین مروی

بهمن ۱۳۹۵

تقدیم به

پدر و روح مادر همیشه خوبم

آنان که وجودم برایشان همه رنج بود و وجودشان برایم همه مهر. مویشان سپیدی گرفت تا رویم سپید بماند. آنان که فروغ نگاهشان، گرمی کلامشان و روشنی رویشان سرمایه جاودانی زندگیم است. آنان که راستی قائم در شکستی قاتشان تجلی یافت. در برابر وجود کرمشان زانو می‌ادب بر زمین می‌نهم و بادی ملوئ از عشق و محبت بردستانشان بوسه می‌زنم.

تقدیر و تشکر

پیش از هر چیز سپاس گزار خداوند منانی، هستم که هر چه داشته و دارم از او ست، بر آستانه بیکرانش سر تعظیم فرود آورده و به پاس حر آن چه به من بخشیده است، سجده شکر به جای می آورم.

سپاس فراوان نثار استادان بزرگوار می که صادقانه و صمیمانه در راه پرورش فرزندان این آب و خاک قدم بر می دارند و در این راه از هیچ کوششی دریغ ندارند. سر تعظیم فرود می آورم بر این همه تواضع و بزرگ نشی و به این همه مناعت طبعی که دارند و عاشقانه در راه اعتلای فرهنگ این مرز و بوم قدم بر می دارند.

بانهایت تواضع و احترام از استاد راهنمای ارجمندم، جناب آقای دکتر حسین مروی تشکر و قدردانی می نمایم. راهنمایی های ایشان کمک بزرگی در انجام این پایان نامه برای اینجانب بود. مهم تر از آن نصیحت های ارزشمندی است که به نوبه آویزه گوش و چراغ راه آینده من است. تشکر صمیمانه خود را به محضر ایشان تقدیم می دارم و می دانم که بی شک انجام این پایان نامه بدون راهنمایی ها و تشویق های ایشان میسر نبود.

همچنین از اعضای محترم کمیته ارزشیابی، جناب آقای دکتر امید رضا معروضی و جناب آقای دکتر سید مسعود میرضایی که بانهایت صبر و تامل این پایان نامه را مورد بررسی قرار داده و نکات ارزشمندی را گوشزد نموده اند، قدردانی می نمایم.

آخر از همه امانه کتر از همه! بهترین سپاس و درود خود را تقدیم به پدر و مادر مهربانم، خواهر، همواره همراهم و دو برادر خنوم می کنم که در هیچ یک از لحظات زندگی مرا تنها گذاشتند و همواره دلم به بودنشان، کمک شان، هدایت شان و محبت شان گرم بود.

تعهد نامه

اینجانب رعنا دهقانی دانشجوی دوره کارشناسی ارشد رشته مهندسی برق/ مخابرات دانشکده مهندسی برق و رباتیک دانشگاه صنعتی شاهرود نویسنده پایان نامه جداسازی گفتار دو گوینده همزمان مبتنی بر ویژگی های مناسب زمان-فرکانس تحت راهنمایی 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 پژوهش های 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 بافت های آن ها) 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 اخلاق 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 فارسی:

یکی از مباحث مهم در زمینه ارتباطات و مخابرات، جداسازی گفتار توسط ماشین می‌باشد که به دلیل مشکلات و ضعف‌های موجود در این سیستم، کماکان به عنوان یک چالش بزرگ باقی مانده است. این در حالی است که سیستم شنیداری انسان در مقایسه با سیستم جداسازی گفتار ماشین توانایی‌های قابل توجهی دارد. لذا با توجه به اختلاف در عملکرد سیستم جداسازی گفتار توسط ماشین و سیستم شنیداری انسان، نیاز به یک سیستم کارآمد برای جداسازی گفتار مورد نظر توسط ماشین در بسیاری از کاربردها محسوس می‌باشد. به عنوان مثال یکی از معایب سیستم تشخیص خودکار گفتار، کاهش عملکرد آن در صورت وجود صداهای مزاحم است. بنابراین چنین سیستمی می‌بایست به یک جداکننده گفتار خوب مجهز شود تا ضمن بهبود عملکرد آن در شرایط مختلف، در بهبود کیفیت گفتار و کاهش هزینه انتقال سیگنال غیرگفتار نیز نقش موثری داشته باشد. از آن جا که انتخاب دقیق واحدهای زمان-فرکانس تاثیر به سزایی در نتایج جداسازی دارد، در این پایان نامه یک روش با نظارت به منظور انتخاب واحدهای زمان-فرکانس مناسب بر پایه ویژگی‌های ضرایب تَنک ارائه می‌شود. در روش پیشنهادی ابتدا نمونه‌ی صدای گوینده‌ها مدل سازی شده که این مدل سازی از طریق آموزش یک دیکشنری و به دست آوردن بردارهای پایه مربوط به هر کدام از گوینده‌ها انجام می‌گیرد. بعد از مدل سازی صدای هر یک از دو گوینده‌ی همزمان، برای هر صدا مطابق با مولفه‌های فرکانسی مربوط به آن عمل جداسازی انجام شده و به منظور کاهش نویز صدای خروجی و حذف مولفه‌های فرکانسی نامرتب، یک مرحله‌ی پس پردازش نیز روی صدای خروجی انجام می‌شود. نتایج آزمایش‌های انجام شده با هدف جداسازی دو گوینده همزمان، نشان دهنده عملکرد قابل توجه روش پیشنهادی در مقایسه با روش‌های مبتنی بر ویژگی و مدل می‌باشد.

کلیدواژه: آنالیز ترکیب شنیداری محاسباتی، جداسازی گفتار دو گوینده همزمان، جداسازی با

نظارت.

فهرست مطالب

عنوان	شماره صفحه
۱- فصل اول.....	۱
۱- پیشگفتار.....	۱
۱-۱- مقدمه.....	۲
۲-۱- سیستم‌های جداسازی گفتار تک‌میکروفونه.....	۴
۳-۱- اهمیت سیستم جداسازی گفتار تک‌میکروفونه.....	۵
۴-۱- ساختار پایان‌نامه.....	۷
۲- فصل دوم.....	۹
۲- مروری بر کارهای انجام شده و مفاهیم پایه.....	۹
۱-۲- مروری بر روش‌های جداسازی منابع صوتی.....	۱۰
۲-۲- آنالیز مؤلفه‌های مستقل.....	۱۰
۲-۲-۱- ابهامات ICA.....	۱۳
۲-۲-۲- غیرگوسی بودن متغیرها در روش ICA.....	۱۴
۳-۲-۲- معیارهای غیرگوسی بودن.....	۱۵
۲-۳-۲-۱- KURTOSIS.....	۱۵
۲-۳-۲-۲- NEGENTROPY.....	۱۷
۳-۲- روش‌های مبتنی بر یادگیری آماری.....	۱۸
۴-۲- مدل‌سازی منبع.....	۲۱
۵-۲- روش‌های بر پایه ویژگی.....	۲۴
۲-۵-۱- روش‌های CASA.....	۲۵
۲-۵-۱-۱- مروری بر روش‌های CASA برای جداسازی گفتار تک‌میکروفونه.....	۲۷
۲-۵-۲- آنالیز مدولاسیون و فیلتر نمودن.....	۳۶
۲-۶- تخمین فرکانس گام.....	۳۹
۲-۷- جمع‌بندی و نتیجه‌گیری.....	۴۱

۴۳	۳- فصل سوم
۴۳	۳- تئوری الگوریتم‌های مورد استفاده
۴۴	۳-۱- روش‌های استخراج ویژگی
۴۴	۳-۱-۱- روش‌های حوزه زمان
۴۴	۳-۱-۲- روش‌های حوزه فرکانس
۴۵	۳-۱-۳- روش‌های حوزه زمان- فرکانس
۴۶	۳-۱-۴- آنالیز پیش‌گویی خطی (LPC)
۴۷	۳-۱-۵- آنالیز کپسترال
۴۸	۳-۱-۶- استفاده از مقیاس MEL در آنالیز کپسترال
۴۹	۳-۲- آموزش دیکشنری
۵۰	۳-۲-۱- کدگذاری تُنک یک سیگنال صوتی
۵۱	۳-۲-۲- الگوریتم OMP
۵۲	۳-۳- جمع‌بندی و نتیجه‌گیری
۵۳	۴- فصل چهارم
۵۳	۴- روش پیشنهادی و پیاده‌سازی آن
۵۴	۴-۱- مقدمه
۵۵	۴-۲- الگوریتم‌های پیشنهادی
۵۶	۴-۳- فاز آموزش
۵۶	۴-۳-۱- بخش‌بندی
۵۷	۴-۳-۲- استخراج ویژگی
۶۱	۴-۳-۳- آموزش دیکشنری
۶۲	۴-۴- فاز تست
۶۲	۴-۴-۱- بخش‌بندی سیگنال تست و استخراج ویژگی
۶۲	۴-۴-۲- تشکیل دیکشنری جامع
۶۲	۴-۴-۳- محاسبه‌ی ضرایب تُنک

۶۳	۴-۴-۴- جداسازی مولفه‌های فرکانسی
۶۴	۴-۴-۵- تبدیل فوریه معکوس
۶۴	۴-۵-۵- پس‌پردازش
۶۴	۴-۵-۱- بخش‌بندی صدای جداسازی شده و استخراج ویژگی
۶۵	۴-۵-۲- انتخاب بهترین فریم
۶۵	۴-۶- جمع‌بندی و نتیجه‌گیری
۶۷	۵- فصل پنجم
۶۷	۵- نتایج تجربی شبیه‌سازی
۶۸	۵-۱- مقدمه
۶۸	۵-۲- پایگاه داده آموزشی
۶۹	۵-۳- معیار ارزیابی
۷۰	۵-۴- نتایج شبیه‌سازی
۷۱	۵-۴-۱- آزمایش اول و دوم دو گوینده هم‌جنس (مرد-مرد)
۷۴	۵-۴-۲- آزمایش سوم و چهارم دو گوینده غیر هم‌جنس (مرد-زن)
۷۴	۵-۴-۳- آزمایش پنجم و ششم دو گوینده هم‌جنس (زن-زن)
۸۰	۵-۴-۴- مقایسه روش پیشنهادی با سایر روش‌ها
۸۱	۵-۴-۵- انجام آزمایش‌ها تحت شرایط نویزی
۸۳	۵-۵- نتیجه‌گیری
۸۵	۵-۶- کارهای آتی
۸۷	۶- مراجع

فهرست اشکال

عنوان	شماره صفحه
شکل (۱-۲) سیگنال‌های اصلی	۱۱
شکل (۲-۲) ترکیب شده سیگنال‌های اصلی با هم	۱۲
شکل (۳-۲) سیگنال‌های تخمین زده شده توسط روش ICA	۱۲
شکل (۴-۲) چگالی توأم دو متغیر گوسی	۱۴
شکل (۵-۲) تابع چگالی توزیع لاپلاس	۱۶
شکل (۶-۲) بلوک دیاگرام ساده‌ای از سیستم CASA	۲۶
شکل (۷-۲) شماتیک ساده‌ای از روش گروه‌بندی ناحیه‌های به‌دست آمده در حوزه زمان-فرکانس در روش‌های CASA	۲۷
شکل (۸-۲) همبستگی نگاشت برای سیگنال گوینده مرد	۲۹
شکل (۹-۲) نمایش اسپکتروگرام سیگنال گفتار و چهار هارمونیک اول آن	۳۷
شکل (۱-۳) نحوه‌ی محاسبه‌ی ضرایب کپسترال	۴۷
شکل (۱-۴) نحوه‌ی تشکیل ماتریس P	۵۷
شکل (۲-۴) ماتریس اندازه‌ی تبدیل فوریه زمان کوتاه مربوط به یک گوینده خاص	۵۹
شکل (۳-۴) نحوه‌ی تشکیل ماتریس ویژگی به‌منظور عملیات پس‌پردازش	۶۰
شکل (۴-۴) تمام ماتریس‌های ساخته شده در مرحله‌ی آموزش برای دو گوینده	۶۱
شکل (۱-۵) بلوک دیاگرام پیشنهادی برای سیستم جداسازی دو گوینده همزمان	۷۱
شکل (۲-۵) مقایسه شکل موج صدای جداسازی شده آزمایش اول (مرد-مرد)	۷۲
شکل (۳-۵) مقایسه شکل موج صدای جداسازی شده آزمایش دوم (مرد-مرد)	۷۳
شکل (۴-۵) مقایسه شکل موج صدای جداسازی شده آزمایش سوم (مرد-زن)	۷۵
شکل (۵-۵) مقایسه شکل موج صدای جداسازی شده آزمایش چهارم (مرد-زن)	۷۶
شکل (۶-۵) مقایسه شکل موج صدای جداسازی شده آزمایش پنجم (زن-زن)	۷۷
شکل (۷-۵) مقایسه شکل موج صدای جداسازی شده آزمایش ششم (زن-زن)	۷۸
شکل (۸-۵) مقایسه اسپکتروگرام صدای جداسازی شده آزمایش ششم (زن-زن)	۷۹

شکل (۵-۹) نمودار مقایسه SNR روش پیشنهادی در مقایسه با سایر روش‌ها ۸۰

شکل (۵-۱۰) نمودار مقایسه SNR ورودی بر حسب خروجی تحت شرایط نویزی (میل‌ای) ۸۰

شکل (۵-۱۱) نمودار مقایسه SNR ورودی بر حسب خروجی تحت شرایط نویزی (خطی) ۸۱

فهرست جداول

عنوان	شماره صفحه
جدول (۵-۱) لیست انتخاب‌های ممکن در پایگاه داده‌ی مورد نظر	۶۷
جدول (۵-۲) مقایسه MSE و SNR روش پیشنهادی با سایر روش‌ها	۷۹
جدول (۵-۳) مقایسه MSE و SNR صدای جداسازی شده‌ی روش پیشنهادی با سایر روش‌ها	۸۱

علائم و اختصارات

ASA.....	Auditory Scene Analysis
ASR.....	Automatic Speech Recognition
BSS.....	Blind Source Separation
CASA.....	Computational Auditory Scene Analysis
HMM.....	Hidden Markov Model
HMS.....	Harmonic Magnitude Suppression
ICA.....	Independent Component Analysis
ISA.....	Independent Subspace Analysis
LPC.....	Linear Predictive Analysis
MFCC.....	Mel Frequency Cepstral Coefficient
NMF.....	Non-negative Matrix Factorization

فصل اول

سیکستار

۱-۱- مقدمه

در زندگی روزمره زمان‌های زیادی پیش می‌آید که شما به همراه دوستان در شهر قدم می‌زنید و با یکدیگر صحبت می‌کنید. در این حین شما صداهای دیگری را نیز از جمله همهمه، فریاد زدن و خندیدن را می‌شنوید. هنگامی که دوست شما صحبت می‌کند، گوش شما مجموعی از صدای دوستان و صداهای دیگران را همزمان می‌شنود. اگر چه در اغلب موارد صدای بلندی از دیگران به گوش می‌رسد، اما باز هم شما به خوبی می‌توانید صدای دوستان را بدون وقفه بشنوید. این طور که به نظر می‌رسد، سیستم شنوایی شما با کمی زحمت قادر به جداسازی گفتار دوستان از صداهای دیگران است.

شرایط نوعی توضیح داده شده چیزی است که ما به طور دائم با آن برخورد می‌کنیم، هنگامی که یک نفر با ما صحبت می‌کند، چیزی که ما می‌شنویم تنها صدای آن شخص نیست، بلکه مخلوط (ترکیبی) از صدای او و صداهای تداخلی دیگر است. تداخل، هر نوع صدایی مانند صدای باد، موزیک و یا گوینده دیگری می‌تواند باشد. در این شرایط، ما نیاز داریم تا صدای هدف و اطلاعات مربوط به آن را از صدای مخلوط شده جدا نماییم. اشخاصی که سیستم شنوایی آن‌ها سالم است می‌توانند به راحتی عملیات جداسازی گفتار هدف را از انواع مختلف تداخل انجام دهند؛ البته باید یادآوری شود که در اکثر مواقع صداهای تداخلی آزاردهنده نمی‌باشند. اما در ارتباط‌های گفتاری با ماشین‌ها و رایانه‌ها، تداخل یک مشکل جدی است و در بسیاری از کاربردها سیستم جداسازی گفتار موثر، مورد نیاز می‌باشد. برای مثال، عملکرد سیستم بازشناسی خودکار گفتار^۱ (ASR) به وسیله صداهای تداخلی شدیداً تخریب می‌شود و با به کارگیری یک سیستم جداسازی گفتار می‌توان عملکرد آن را بهبود بخشید. همچنین به کارگیری سیستم جداسازی گفتار در سیستم‌های مخابراتی باعث بهبود کیفیت گفتار و کاهش هزینه‌ها در ارسال سیگنال‌های غیرگفتاری می‌گردد. علاوه بر این، صدای تداخلی یک مشکل جدی برای افرادی است که مشکل شنوایی دارند و برای دریافت گفتار هدف مجبورند از

¹Automatic Speech Recognition

سمک استفاده کنند. برای کمک به این افراد باید سمک‌ها به نحوی طراحی شوند که بتواند گفتار هدف را از مخلوط‌های صوتی جدا نماید.

پژوهش‌های زیادی برای گسترش سیستم‌های محاسباتی که به‌طور خودکار توانایی جداسازی و یا تضعیف تداخل از گفتار هدف را دارا می‌باشند، انجام گرفته است. بسیاری از این پژوهش‌ها بر روی موقعیت‌هایی متمرکز شده‌اند که منابع هدف و تداخل، در دو مکان متفاوت قرار گرفته‌اند و چندین میکروفون در دسترس می‌باشند. یکی از راه‌حل‌های ارائه شده در برخورد با این موضوع، تضعیف سیگنال تداخلی با استفاده از فیلترهای فضایی^۱ است که در آن سیگنال‌های رسیده از جهت منبع هدف، استخراج و سیگنال‌های رسیده از جهت منبع تداخل، حذف می‌شود [۱]؛ اما در شرایطی که جهت منابع هدف و تداخل یکسان بوده و یا تنها یک میکروفون و یک صدای ضبط‌شده در دسترس باشد، نمی‌توان از این روش‌ها استفاده کرد. روش جداسازی کور منابع^۲ (BSS) با استفاده از تکنیک آنالیز مؤلفه‌های مستقل^۳ (ICA)، سیگنال‌های مخلوط را به اجزائی تجزیه می‌کند که از لحاظ آماری از یکدیگر مستقل می‌باشند. در شرایطی که جهت منابع هدف و تداخل متفاوت باشند و تعداد میکروفون‌ها از تعداد منابع بزرگ‌تر و یا مساوی آن‌ها باشد، روش ICA به‌خوبی کار می‌کند؛ اما در شرایطی که تنها یک میکروفون در دسترس باشد، نمی‌توان از این روش استفاده نمود.

در کاربردهایی مانند ارتباطات مخابراتی و بازیابی اطلاعات صوتی، نیاز به راه‌حل‌هایی برای جداسازی گفتار در شرایط تک‌میکروفون می‌باشد. راه‌حل‌های ارائه شده از خواص ذاتی سیگنال هدف و تداخل برای تشخیص و جداسازی آن‌ها از یکدیگر استفاده می‌کنند. الگوریتم‌های بسیاری برای بهسازی گفتار تک‌میکروفون ارائه گردیده است که این الگوریتم‌ها به‌طور کلی بر پایه آنالیز گفتار و تداخل و در نتیجه تقویت گفتار و کاهش تداخل می‌باشند. به‌عنوان مثال در [۲]، الگوریتم‌هایی ارائه

¹ Spatial Filters

² Blind Source Separation

³ Independent Component Analysis

شده است که در آن طیف زمان کوتاه تداخل تخمین زده می‌شود و بر اساس آن تداخل تضعیف می‌یابد و یا در [۳] بر اساس مدل‌سازی گفتار، عمل جداسازی انجام می‌گیرد.

در راه‌های دیگر مخلوط آکوستیکی براساس تجزیه ویژه نمایش داده شده و سپس از آنالیز زیرفضا، برای از بین بردن تداخل استفاده می‌شود. مدل‌های مارکف مخفی روش دیگری است که برای مدل‌سازی گفتار و تداخل سپس جداسازی آن‌ها به کار برده می‌شود [۴].

این مدل‌سازی بر اساس خواص معینی از تداخل انجام می‌گیرد و به همین منظور قابلیت برخورد با هر نوع تداخلی را ندارد، چرا که تنوع زیاد تداخل‌ها عمل مدل‌سازی و پیش‌بینی را مشکل می‌کند.

۱-۲- سیستم‌های جداسازی گفتار تک‌میکروفونه

در حالی که سیستم‌های جداسازی گفتار تک‌میکروفونه هنوز با مسائل حل نشده‌ی بسیاری مواجه هستند، سیستم شنوایی انسان با توانایی قابل توجهی، قادر به جداسازی گفتار می‌باشد. همین مسأله الهام‌بخش، باعث ایجاد یک راه‌حل جدید و متفاوت از دیگر روش‌های موجود برای جداسازی گفتار تک‌میکروفونه بر اساس فرآیند جداسازی سیستم شنوایی شد.

با توجه به فرآیند جداسازی در سیستم شنوایی انسان، در سال ۱۹۹۴ Bregman سیستمی با موضوع تحلیل صحنه شنیداری^۱ (ASA) برای جداسازی تک‌میکروفونه مطرح کرد [۵]. این سیستم جداسازی شامل دو مرحله می‌باشد: مرحله اول، بخش‌بندی^۲ نامیده می‌شود، واحدهای زمان-فرکانس^۳ (T-F) سیگنال مخلوط به بخش‌هایی تجزیه می‌شود که هر کدام از این بخش‌ها از یک منبع به وجود آمده‌اند. مرحله دوم گروه‌بندی^۴ نامیده می‌شود که در آن بخش‌های مربوط به یک منبع، با یکدیگر تشکیل یک گروه می‌دهند. بخش‌بندی و گروه‌بندی با توجه به اصول ادراکی (ویژگی‌های ASA) انجام می‌گیرد و بر اساس این ویژگی‌ها می‌توان فهمید که سیستم شنوایی چگونه سازماندهی شده است.

^۱Auditory Scene Analysis

^۲Segmentation

^۳Time-Frequency

^۴Grouping

این ویژگی‌ها خواص ذاتی گفتار را مشخص می‌کنند و عبارتند از: harmonicity، فراز^۱ و فرود^۲، مکان و اطلاعات قبلی از صداهای خاص.

پژوهش‌های انجام شده در زمینه ASA، [۶] الهام‌بخش کارهای قابل توجهی برای ساخت سیستم‌های آنالیز محاسباتی نمایش شنوایی^۳ (CASA) برای جداسازی گفتار شده است. بسیاری از سیستم‌های CASA برای شرایط دومیکروفون به پیشنهاد شده‌اند و مبنای آن‌ها بر این است که سیستم‌شنوایی انسان با توجه به متفاوت بودن مکان منابع صدا، قادر به مکان‌یابی منابع و در نتیجه جداسازی اصوات از جهت‌های گوناگون می‌باشد [۵، ۷، ۸]. سیستم شنوایی با مقایسه سیگنال‌های رسیده به دو گوش (در نقش دو میکروفون) مکان منابع را پیدا کرده و با استفاده از جهت منابع، صدای هدف را از صدای تداخلی جدا می‌کند.

در واقع سیستم‌های دومیکروفون در شرایطی که جهت منابع هدف و تداخل قابل تفکیک باشد، دارای عملکرد قابل توجهی می‌باشند. توجه کنید در شرایطی که جهت منابع یکسان باشد و یا یک میکروفون در دسترس باشد، روش‌های دومیکروفون قادر به جداسازی منابع نمی‌باشند. در چندین سال اخیر تلاش‌های زیادی برای گسترش سیستم‌های CASA در شرایط تک‌میکروفون انجام گرفته است. هدف این سیستم‌ها، جداسازی صدای هدف بدون در نظر گرفتن فرضیاتی درباره تداخل و افزایش کاربردهای آن نسبت به روش‌های بهسازی گفتار بوده است [۹، ۱۰].

۱-۳- اهمیت سیستم جداسازی گفتار تک‌میکروفون

در کاربردهای واقعی، گفتار توسط یک یا چند میکروفون ضبط گردیده و برای پردازش‌های چند بعدی به رایانه‌ها فرستاده می‌شود. البته اگر این امکان وجود داشته باشد، ضبط گفتار با چند میکروفون در اولویت است. در این حالت اطلاعات مکانی نیز می‌تواند ذخیره شود و به‌عنوان ویژگی‌های اضافی برای جداسازی گفتار به کار برده می‌شود. اگرچه در محیط‌هایی با چندین منبع

¹Onset

²Offset

³Computational Auditory Scene Analysis

صدا، چنانچه گوینده هدف از قبل تعیین نشده باشد، آرایه‌های میکروفونی ممکن است مفید واقع نشوند و حتی در مواردی ممکن است شرایط محیطی، قابلیت استفاده از چندین میکروفون را فراهم نسازد. در بسیاری از این حالت‌ها استفاده از یک میکروفون، تنها انتخاب ممکن است.

یکی از کاربردهای جداسازی گفتار تک‌میکروفونه، در بازشناسی خودکار گفتار، پخش رادیویی است. در این موارد، سیگنال گفتار ارسال شده توسط کانال‌های رادیویی، جمع‌آوری می‌شود و در نتیجه هیچ‌گونه اطلاعات مکانی در دسترس نمی‌باشد. در طول ارسال گفتار هدف، برخی از قسمت‌های آن به‌وسیله گفتار گوینده‌های تداخلی تخریب شده و این مسأله باعث پایین آمدن دقت سیستم بازشناسی گفتار می‌شود. یکی دیگر از کاربردهای سیستم جداسازی در سیستم بازشناسی گفتار، مکالمه‌های کنفرانسی از راه دور می‌باشد. در واقع وجود چندین گوینده تداخلی، باعث تخریب عملکرد سیستم بازشناسی گفتار می‌شود.

خروجی سیستم بازشناسی گفتار به‌عنوان ورودی برای سیستم‌هایی مانند جمع‌آوری اخبار، سیستم‌های مکالمه و سیستم‌های تبدیل متن به گفتار مورد استفاده قرار می‌گیرد. تمامی این سیستم‌ها برای بالا بردن دقت بازشناسی گفتار، نیاز به یک سیستم جداسازی گفتار تک‌میکروفونه با عملکرد خوب دارند؛ زیرا دقت پایین سیستم بازشناسی گفتار باعث افزایش جدی خطاها می‌شود. به‌همین دلیل وجود یک سیستم جداسازی گفتار با دقت بالا بسیار حائز اهمیت است.

همانطور که بیان شد، برخلاف سیستم چندمیکروفونه، سیستم تک‌میکروفونه به اطلاعات مکانی دسترسی ندارد و به‌همین دلیل تنها از ویژگی‌های آکوستیکی ذاتی مانند فرکانس گام، ساختار سیستم هارمونیک و زمان محلی^۱ یا مجاورت فرکانسی^۲ برای جداسازی گفتار استفاده می‌کند. اطلاعات فرکانس گام به‌عنوان یک ویژگی خوب برای استخراج ساختار هارمونیک مورد توجه قرار گرفته است. اما تخمین دقیق نمودارهای فرکانس گام گفتار هدف در حضور گفتار تداخلی دیگر، کاری

¹Local Time

²Frequency Proximity

بسیار سخت است؛ زیرا رفتار گفتار تداخلی برخلاف نویزهای دیگر مانند نویز سفید/ رنگی و یا نویز ماشین‌ها بسیار شبیه گفتار هدف است.

۱-۴- ساختار پایان‌نامه

این پایان‌نامه شامل پنج فصل است که محتوای کلی آن به شرح زیر می‌باشد:

در فصل دوم، ابتدا روش‌های موجود برای جداسازی منابع گفتاری را دسته‌بندی کرده و بر روی روش‌های موجود در هر دسته، مروری مختصر داریم. سپس به بررسی روش‌های تک‌میکروفون بر پایه ویژگی برای جداسازی منابع می‌پردازیم. در یک دسته‌بندی کلی می‌توان روش‌های جداسازی بر پایه ویژگی را به دو دسته، روش‌های CASA و روش‌های بر پایه آنالیز مدولاسیون و فیلتر نمودن طبقه‌بندی نمود. ابتدا مروری بر روی سیستم‌ها و روش‌های ارائه شده در هر کدام از این دسته‌ها داشته و سپس مزایا و معایب هر کدام از آن‌ها را مورد بررسی قرار می‌دهیم.

در فصل سوم، تئوری الگوریتم‌های مورد استفاده برای استخراج ویژگی را توضیح می‌دهیم. در واقع روش‌های استخراج ویژگی را به دو دسته زمان و فرکانس تقسیم کرده و هر کدام را جداگانه بیان می‌کنیم. در ادامه فصل به روش‌هایی می‌پردازیم که اطلاعات دو حوزه را با هم در بر می‌گیرد. به‌عنوان مثال، روش‌های آنالیز پیش‌گویی خطی و آنالیز کپسترال را می‌توان نام برد. بعد از معرفی روش‌های استخراج ویژگی در مورد روش آموزش دیکشنری مورد استفاده در روش پیشنهادی توضیح می‌دهیم. این بخش شامل زیرمجموعه کدگذاری تنک یک سیگنال صوتی و الگوریتم OMP می‌باشد که به شرح آن می‌پردازیم.

در فصل چهارم، روش پیشنهادی و پیاده‌سازی الگوریتم مورد استفاده در روش پیشنهادی خود را بیان می‌کنیم. ساختار این فصل شامل سه فاز می‌باشد. فاز آموزش، فاز تست و فاز پس‌پردازش. در هر بخش فاز مربوطه را کامل شرح می‌دهیم.

در فصل پنجم، الگوریتم‌های مطرح شده، در محیط نرم‌افزار MATLAB شبیه‌سازی شده و طی آن، روش پیشنهادی در پایان‌نامه را مورد ارزیابی قرار می‌دهیم. نتایج شبیه‌سازی نشان می‌دهد که

روش پیشنهادی توانسته است نسبت به سایر روش‌ها از SNR بالاتر و بهتری برخوردار باشد. در نهایت، نتایج کلی به دست آمده در این پایان‌نامه و پیشنهادهایی برای ادامه کار بیان شده است.

فصل دوم

مروری بر کارهای انجام شده و مفاهیم

پایه

۲-۱- مروری بر روش های جداسازی منابع صوتی

در این فصل ابتدا روش های موجود برای جداسازی منابع را دسته بندی کرده و سپس بر روی روش های موجود در هر دسته، مروری مختصر داریم. هدف از انجام این پایان نامه، ارائه سیستمی با کارایی بالا برای جداسازی گفتار در شرایطی است که تنها یک میکروفون در دسترس باشد. به همین دلیل در ادامه این فصل به بررسی دقیق تر روش های جداسازی گفتار همزمان می پردازیم. به طور کلی روش های موجود برای جداسازی گفتار همزمان را می توان به صورت زیر دسته بندی کرد:

۱. آنالیز مؤلفه های مستقل (ICA)

۲. روش های مبتنی بر یادگیری آماری^۱

۳. روش های بر پایه مدل سازی

۴. روش های بر پایه ویژگی

۲-۲- آنالیز مؤلفه های مستقل

تصور کنید در یک اتاق که در آن دو نفر به طور همزمان در حال صحبت هستند، قرار دارید. دو میکروفون، که در مکان های مختلف گذاشته شده اند، موجود می باشد. میکروفون ها دو سیگنال ثبت شده زمانی را که با $x_1(t)$ و $x_2(t)$ نشان داده شده، در اختیار قرار می دهند. توجه داشته باشید x ها دامنه و t ها شاخص زمان هستند. هر یک از این سیگنال های ثبت شده، مجموع وزن سیگنال های گفتار ادا شده توسط دو گوینده هستند که با نماد $s(t)$ نمایش داده می شوند. معادله خطی عبارت است از:

$$x_1(t) = a_{11}s_1 + a_{12}s_2 \quad (1-2)$$

$$x_2(t) = a_{21}s_1 + a_{22}s_2 \quad (2-2)$$


¹Statistical Learning

a_{ij} ها پارامترهایی هستند که به فاصله میکروفون‌ها از گوینده‌ها بستگی دارند. اگر بتوان دو سیگنال گفتار اصلی، یعنی $s_i(t)$ ها را با استفاده از سیگنال‌های ثبت شده $x_i(t)$ تخمین زد، بسیار مفید خواهد بود. این مسئله به‌عنوان کوکتل-پارتی^۱ نامیده شده‌است. توجه گردد که هیچ‌گونه تأخیر یا فاکتور اضافی، در مدل آزمایشی وارد نمی‌شود.

به‌عنوان مثال، شکل موج‌های شکل (۱-۲) و شکل (۲-۲) را در نظر بگیرید، البته توجه گردد که این شکل موج‌ها سیگنال گفتار واقعی نیستند. سیگنال‌های گوینده در شکل (۱-۲) و مخلوط سیگنال‌ها در شکل (۲-۲) آورده شده است. حال مسئله جداسازی این شکل موج‌ها مطرح می‌باشد.


در واقع، اگر پارامترهای a_{ij} موجود باشند، مسئله حل شده است؛ در غیر این‌صورت، مسئله پیچیده‌تر و شامل در نظر گرفتن موارد دیگر در حل این مسئله می‌باشد.

در سال‌های اخیر روش آنالیز مولفه‌های مستقل بسیار توسعه یافته است. به‌طوری‌که می‌تواند با استفاده از تخمین a_{ij} ها مبتنی بر اطلاعات مستقل آن‌ها، امکان جداسازی دو سیگنال اصلی را از سیگنال‌های مخلوط شده انجام دهد. شکل (۳-۲) سیگنال‌های تخمین زده شده توسط روش ICA را نشان می‌دهد. همان‌طور که دیده می‌شود این سیگنال‌ها بسیار نزدیک به سیگنال اصلی هستند.




شکل (۱-۲) سیگنال‌های اصلی [۱۱]

^۱Cocktail-party



شکل (۲-۲) ترکیب شده سیگنال‌های اصلی با هم [۱۱]



شکل (۳-۲) سیگنال‌های تخمین زده شده توسط روش ICA [۱۱]

در آنالیز مولفه‌های مستقل بردار $x(k) \in R^m$ با یافتن ماتریس جداسازی $n \times m$ (که $m \geq n$ است) W بدست می‌آید. W از رتبه کامل^۱ است و طوری به‌دست می‌آید که بردار سیگنال خروجی تخمین زده شده $y(k) = [y_1(k), \dots, y_n(k)]^T$ ، تا حد امکان مستقل باشد.

$$y(k) = W.x(k) \quad (۳-۲)$$

استقلال متغیرهای تصادفی، مفهوم کلی‌تری از ناهمبستگی است. می‌توان گفت متغیرهای تصادفی y_i و y_j از لحاظ آماری مستقل هستند اگر اطلاعات درباره مقادیر y_i هیچ اطلاعاتی را درباره مقادیر y_j فراهم نکند. از لحاظ ریاضی استقلال بین y_i و y_j را می‌توان با رابطه زیر بیان کرد [۱۱]:

$$p(y_i, y_j) = p(y_i) \cdot p(y_j) \quad (۴-۲)$$

^۱Full rank

$p(y)$ نشان‌دهنده تابع چگالی احتمال متغیر تصادفی y است. به بیان دیگر سیگنال‌ها مستقل هستند، اگر تابع چگالی احتمال آن‌ها قابل جداسازی باشد.

ICA یک روش محاسباتی برای تجزیه یک سیگنال به زیرمؤلفه‌های جمع‌شونده با فرض استقلال آماری سیگنال‌های منابع غیرگوسی است. این روش، یک مورد خاص از روش‌های جداسازی کور منابع است. در پردازش‌های چند میکروفونه تحت شرایط خاص، امکان جداسازی کامل منابع از سیگنال‌های مخلوط با استفاده از روش ICA وجود دارد [۱۱]. این شرایط عبارتند از:

- تعداد میکروفون‌ها برابر و یا بیشتر از تعداد منابع باشد. به بیان دیگر تعداد ترکیبات خطی مشاهده شده نباید کمتر از تعداد مولفه‌های مستقل باشد.
- منابع باید از یکدیگر مستقل باشند. در واقع تمام مولفه‌های مستقل به جز یکی از این مولفه‌ها باید غیرگوسی باشند.
- تعداد منابع در سیگنال‌های مخلوط مشاهده شده معین باشد.
- ماتریس A باید از مرتبه کامل باشد.

۲-۱-۲- ابهامات ICA

در مدل ICA به صورت $x = A.s$ این ابهامات قابل مشاهده است [۱۱]:

اول این که نمی‌توان انرژی مولفه‌های مستقل را تعیین کرد. رابطه $x = \sum_{i=1}^n a_i . s_i$ را در نظر بگیرید. از آن جا که s و A هر دو نامعلوم هستند هر اسکالری که در هریک از منابع s_i ضرب شود، می‌تواند توسط تقسیم ستون متناظر a_i در A با همان اسکالر حذف شود. در نتیجه می‌توان دامنه مولفه‌های مستقل را ثابت در نظر گرفت. با توجه به این که مولفه‌ها، متغیر تصادفی هستند بهترین راه برای انجام این کار فرض واریانس واحد $E\{s_i^2\} = 1$ برای هر یک از این مولفه‌هاست. سپس ماتریس A با در نظر گرفتن این محدودیت به دست می‌آید. این ابهام در بیشتر کاربردها قابل اغماض است.

دوم این که نمی توان ترتیب مولفه های مستقل را تعیین کرد. به بیان ریاضی ماتریس جایگشت P و معکوس آن را می توان این گونه در مدل جایگزین کرد: $x=AP^{-1}Ps$. عناصر Ps متغیرهای مستقل منابع اصلی S_i در یک ترتیب جدید هستند و ماتریس AP^{-1} یک ماتریس ترکیب کننده نامعلوم جدید است که توسط الگوریتم های ICA به دست می آید.

۲-۲-۲- غیرگوسی بودن متغیرها در روش ICA

یکی از محدودیت های اساسی ICA این است که مولفه های مستقل نباید گوسی باشند. فرض کنید ماتریس ترکیب کننده متعامد و S_i ها گوسی هستند و x_1 و x_2 گوسی، ناهمبسته و با واریانس واحد هستند. در این صورت چگالی توأم آن ها به شکل زیر است:

$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(\frac{-x_1^2 + x_2^2}{2}\right) \quad (۲-۵)$$

این توزیع در شکل (۲-۴) آورده شده است. با توجه به شکل مشخص است که چگالی کاملاً متقارن است. بنابراین شامل هیچ گونه اطلاعاتی در جهت ستون های ماتریس ترکیب کننده A نمی باشد. به همین دلیل A قابل تخمین نیست. اگر فقط یکی از مولفه های مستقل گوسی باشد مدل ICA قابل تخمین است.



شکل (۲-۴) چگالی توأم دو متغیر گوسی [۱۱]

۲-۲-۳- معیارهای غیرگوسی بودن

برای بررسی غیرگوسی بودن نیاز به یک معیار کمی است. دو تا از معیارهای غیرگوسی بودن را که در این جا معرفی می‌شود عبارتند از [۱۱]:

Kurtosis (a)
Negentropy (b)

Kurtosis - ۱-۳-۲-۲

معیار کلاسیک غیرگوسی بودن kurtosis یا کومولانت مرتبه چهارم است و به این صورت تعریف می‌شود:

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2 \quad (۲-۶)$$


از آن جا که فرض می‌شود y دارای میانگین صفر و واریانس واحد باشد، بنابراین سمت راست رابطه بالا به صورت $E\{y^4\} - 3$ ساده می‌شود. این امر نشان می‌دهد که kurtosis شکل نرمالیزه شده ممان چهارم یعنی $E\{y^4\}$ می‌باشد. برای یک متغیر گوسی، kurtosis صفر و برای اکثر متغیرهای غیر گوسی، مخالف صفر می‌باشد. kurtosis می‌تواند مثبت یا منفی باشد. متغیرهای تصادفی کوه کurtosis آن‌ها منفی است، زیرگوسی^۱ و متغیرهای تصادفی که kurtosis آن‌ها مثبت است، فراگوسی^۲ نامیده می‌شوند. متغیرهای تصادفی فراگوسی نوعاً دارای تابع چگالی احتمال‌های نوک تیز هستند، به طوری که pdf آن‌ها در صفر دارای اندازه بزرگی می‌باشند؛ در حالی که در مقادیر متوسط مقدار pdf آن‌ها کم است. به عنوان مثال می‌توان به توزیع لاپلاس که pdf آن به واریانس ۱ نرمالیزه شده است، به صورت زیر اشاره کرد:

$$p(y) = \frac{1}{\sqrt{2}} \exp(\sqrt{2}|y|) \quad (۲-۷)$$

این pdf در شکل (۲-۵) رسم شده است. خطوط نقطه‌چین تابع چگالی توزیع گوسی را نشان می‌دهد. هر دو چگالی به واریانس یک نرمالیزه شده‌اند.

^۱Sub-Gaussian

^۲Super-Gaussian



شکل (۵-۲) تابع چگالی توزیع لاپلاس [۱۱]

متغیرهای تصادفی زیرگوسی نوعاً دارای یک pdf صاف می‌باشند. مقادیر این pdf نزدیک به صفر، ثابت است و در مقادیر بزرگتر، مقدار pdf بسیار کوچک است. مثال این pdf توزیع یکنواخت است. چه از لحاظ محاسباتی و چه از لحاظ تئوری معیار kurtosis ساده می‌باشد. از نظر محاسباتی kurtosis به سادگی توسط محاسبه ممان مرتبه چهارم قابل دستیابی است. همچنین از نظر آنالیزهای تئوری نیز ساده می‌باشد چرا که دارای دو خاصیت خطی زیر است:

$$kurt(x_1 + x_2) = kurt(x_1) + kurt(x_2) \quad (۸-۲)$$

$$kurt(ax_1) = a^4 kurt(x_1) \quad (۹-۲)$$

که a یک اسکالر است. برای محاسبه مولفه‌های مستقل توسط این معیار، در عمل از یک بردار وزن W شروع می‌شود و جهتی را که $kurt(y)$ در آن جهت ماکزیمم (در صورت مثبت بودن kurtosis) یا مینیمم (در صورت منفی بودن) می‌شود را پیدا می‌کند و از روش گرادیان و یا یکی از بسط‌هایش جهت محاسبه W جدید استفاده می‌کنیم. همچنین مشکل عمده این معیار ناپایداری آن است.

Negentropy - ۲-۳-۲-۲

یک معیار مهم دیگر برای غیر گوسی بودن negentropy است. این معیار براساس کمیت تئوری اطلاعاتی آنتروپی تفاضلی می‌باشد. آنتروپی یک مفهوم اصلی در تئوری اطلاعات است. آنتروپی یک متغیر تصادفی، به صورت میزان اطلاعاتی که آن متغیر به ما می‌دهد، بیان می‌شود. هرچه متغیر تصادفی تر یعنی غیر قابل پیشگویی باشد، مقدار آنتروپی نیز بیشتر است.

آنتروپی H برای یک متغیر تصادفی گسسته به صورت زیر تعریف می‌شود:

$$H(Y) = - \sum_i P(Y = a_i) \cdot \log P(Y = a_i) \quad (۱۰-۲)$$

که a_i مقادیر ممکن y می‌باشد. این تعریف را می‌توان به متغیرهای تصادفی پیوسته نیز تعمیم داد که در این حالت آنتروپی تفاضلی گفته می‌شود. آنتروپی تفاضلی بردار تصادفی y با چگالی $f(y)$ به صورت زیر تعریف می‌شود:

$$H(y) = - \int f(y) \cdot \log f(y) dy \quad (۱۱-۲)$$

یکی از نتایج اصلی تئوری اطلاعات این است که متغیر گوسی بیشترین آنتروپی را در میان متغیرهای تصادفی با واریانس یکسان دارد. این بدان معناست که می‌توان از این ویژگی جهت معیار غیر گوسی بودن استفاده کرد. شکل اصلاح شده، آنتروپی تفاضلی negentropy نامیده شده و به صورت زیر تعریف می‌شود:

$$J(y) = H(y_{gauss}) - H(y) \quad (۱۲-۲)$$

که y_{gauss} یک متغیر تصادفی با ماتریس کوواریانس مشابه y می‌باشد. negentropy همیشه غیر منفی و صفر است اگر و تنها اگر y دارای توزیع گوسی باشد. از دیگر ویژگی جالب negentropy متغیر نبودن آن نسبت به تبدیلات خطی معکوس پذیر است. همچنین یکی از مشکلات این معیار، پیچیدگی محاسباتی آن است. تخمین negentropy با استفاده از تعریف، نیاز به تخمین تابع چگالی احتمال دارد. بنابراین تقریب‌های ساده تری از negentropy بسیار مفید خواهند بود.

در واقع شرایط بیان شده در بالا باعث ایجاد محدودیت‌هایی در استفاده از ICA به عنوان یک راه حل برای مسأله جداسازی گفتار تک میکروفونه می شود. در [۱۲] جهت گسترش روش جداسازی کور منابع برای مسأله جداسازی گفتار تک میکروفونه، از روش بیشترین شباهت برای پیشنهاد یک الگوریتم ICA با نظارت، استفاده کرده است. روش پیشنهادی برای مخلوطی از سیگنال گفتار و موزیک به خوبی عمل می کند؛ اما در شرایطی که سیگنال‌های مخلوط گفتار باشند، عملکرد آن به شدت افت می کند [۱۲]. این به دلیل همپوشانی زیاد سیگنال‌های گفتار در حوزه زمان و فرکانس است. در [۱۳]، روش ICA با یک ماسک زمان-فرکانس برای جداسازی گفتار با استفاده از دو میکروفون ترکیب می شود. در این روش فرض بر این است که هیچ اطلاعی از تعداد منابع صوتی در دسترس نمی باشد.

نوع دیگری از روش ICA، روش آنالیز زیر فضای مستقل (ISA)^۱ است که این روش، پردازش سیگنال‌های مشاهده شده را با افزایش بعد آن‌ها از ۱ به N انجام می دهد. عملکرد ISA بر روی سیگنال به صورت تجزیه آن به یک مجموعه با N پایه مستقل است. به طوری که باید این پایه‌ها با یکدیگر گروه بندی شوند و تشکیل زیرمجموعه‌هایی وابسته به هر منبع موجود در سیگنال مخلوط را بدهند. James و Davies نشان داده اند که ISA زمانی می تواند یک روش کارآمد باشد که طیف منابع از یکدیگر جدا باشند و این بدین مفهوم است که استقلال خطی پایه‌ها تضمین می شود [۱۴]. ISA با به کارگیری مؤلفه‌های دینامیکی برای نمایش سیگنال‌های غیریستا، توسعه یافته روش ICA است. در روش ISA برخلاف ICA نیاز به داشتن میکروفون‌هایی حداقل برابر با تعداد منابع نمی باشد. بنابراین تعداد سیگنال‌های مخلوط مورد نیاز از یک سیگنال به بالا می تواند باشد [۱۴].

۲-۳- روش‌های مبتنی بر یادگیری آماری

در روش‌های یادگیری آماری هیچ فرضی در مورد منابع در نظر گرفته نمی شود.

¹Independent Subspace Analysis

در این روش‌ها، یادگیری بر اساس داده‌های مخلوط مشاهده شده و یا داده‌های قبلی موجود از هر کدام از منابع است. در ادامه به برخی کارهای انجام‌شده در این زمینه اشاره‌ای مختصر می‌گردد.

Roweis در [۱۵] یک مدل مارکف مخفی^۱ (HMM)، برای داده‌های گفتار تمیز از یک گوینده را آموزش می‌دهد. در این روش با ترکیب HMM دو گوینده یک HMM وابسته تولید می‌شود که با استفاده از آن، احتمال این که یک نقطه در حوزه زمان-فرکانس سیگنال مخلوط مشاهده شده، مربوط به کدام گوینده است، تخمین زده می‌شود. جداسازی منابع به‌وسیله بازسازی سیگنال از نقاط زمان-فرکانسی است که با احتمال بیشتری متعلق به گوینده مورد نظر می‌باشند و دیگر نقاط زمان-فرکانس صفر در نظر گرفته می‌شود.

دیدگاه Bach و Jordan به مسأله جداسازی منابع به‌صورت یک مسأله بخش‌بندی زمان-فرکانس است [۱۶]. در این روش به‌جای مدل کردن رفتار منابع به‌طور جداگانه، طیف سیگنال به دو یا چند مجموعه گسسته بخش‌بندی می‌شود. مجموعه‌ای از ویژگی‌ها مانند: فراز-فرود و فرکانس گام در حوزه زمان-فرکانس برای بخش‌بندی‌کننده^۲ تولید می‌گردد. بخش‌بندی‌کننده طیفی، به‌وسیله ماتریس‌های مشابهت، پارامتری را برای هر ویژگی در فضای ویژگی‌ها تعریف می‌کند. مقادیر پارامترهای ماتریس مشابهت به‌وسیله داده‌های یادگیری و با استفاده از الگوریتم یادگیری طیف محاسبه می‌گردد.

روش دیگر برای جداسازی منابع در حوزه زمان-فرکانس، نمایش حوزه زمان-فرکانس سیگنال مخلوط مشاهده شده به‌وسیله یک ترکیب خطی از بردارهای پایه می‌باشد که این بردارهای پایه نمایشگر هر منبع هستند. دو روش معمول برای تخمین بردارهای پایه برای یک منبع، کوانتیزاسیون برداری [۱۷] و ماتریس فاکتوریل نامنفی [۱۸] است.

^۱Hidden Markov Model

^۲Segmenter

در [۱۷]، Ellis و Weiss یک کتاب کد کوانتیزاسیون برداری برای فریم‌های طیف زمان کوتاه داده‌های آموزشی یک منبع تولید کردند. در این روش سیگنال مخلوط مشاهده شده، به بردارهای کتاب کد منابع تصویر می‌شوند و در نهایت سیگنال جدا شده از بردارهایی که بیشترین تطابق را با یکدیگر دارند، ساخته می‌شوند. برای تکمیل این روش، یک HMM برای اعمال محدودیت‌های ترتیبی بین بردارهای کتاب کد، به آن افزوده شده است. این روش بر روی سیگنال گفتار مخلوط شده با نویزی شبیه گفتار، ارزیابی شده است. نتایج نشان می‌دهد که در برخی مواقع سیگنال گفتار به‌خوبی بهسازی نگردیده است.

در روش فاکتورگیری ماتریس نامنفی^۱ (NMF) [۱۸]، دامنه تبدیل فوریه زمان کوتاه داده آموزشی از یک منبع، به‌وسیله حاصل ضرب یک ماتریس نامنفی الگوهای طیفی در یک ماتریس نامنفی الگوی زمانی مرتبط به‌دست می‌آید: $Y = HW$ ، که در این رابطه، ستون‌های ماتریس H بردارهای پایه‌ای هستند که با یکدیگر ساختار طیفی نمایش زمان-فرکانس سیگنال مخلوط را معین می‌کنند. همچنین سطرهای ماتریس W ساختار زمانی و وزن‌هایی را تعریف می‌کنند که به‌وسیله آن‌ها منابع در ماتریس مخلوط Y فعال هستند. سپس همین تکنیک بر روی سیگنال مخلوط مشاهده شده، اعمال می‌گردد. جداسازی به‌وسیله سنتز دامنه تبدیل فوریه زمان کوتاه از الگوهای طیفی و زمانی از منبع مطلوب به-دست می‌آید.

روش NMF عمل جداسازی را با تصویر یک بردار ویژگی مخلوط به زیرفضای پیوسته منابع و سپس محاسبه قسمت‌های مربوطه به هر زیرفضا انجام می‌دهد [۱۸]. [۱۹] یک روش آنالیزی را جهت معین نمودن شرایطی که تحت آن تنها یک ماتریس NMF واحد وجود داشته باشد، به‌کار می‌گیرد. چندین نوع الگوریتم NMF برای یادگیری ماتریس H و W از روی ماتریس Y بر پایه قیدهای پیوستگی زمانی [۲۰] و یا بر پایه قیدهای تنکی [۱۸] جهت بهبود کیفیت سیگنال جدا شده پیشنهاد شده است. در [۲۱] یک الگوریتم تجزیه نامنفی تنک برای جداسازی منابع صوتی در شرایط

¹Non-negative Matrix Factorization

تک‌میکروفونه ارائه شده است. در این روش، الگوریتم فیلتر وینر با تعمیم شرط ایستایی محلی به مدل منابع پارامتری غیرگوسی بهبود داده می‌شود. در [۲۲]، با تکیه بر پردازش گوسی اطلاعات قبلی، یک روش کلی برای به‌کارگیری اطلاعات قبلی برای NMF ارائه شده است. روش پیشنهادی در [۲۲] نشان می‌دهد که با انتخاب توزیع قبلی مناسب می‌توان به نتایج بهتری نسبت به روش NMF رسید.

NMF به‌منظور جداسازی گفتار تک‌میکروفونه به دو صورت به‌کار برده می‌شود: با نظارت^۱ و بدون نظارت^۲. در روش بدون نظارت NMF به‌طور مستقیم و بدون داشتن اطلاعات قبلی از منابع، طیف سیگنال مخلوط را به طیف‌های سیگنال‌های موجود در سیگنال مخلوط تجزیه می‌کند. روش NMF با نظارت، این عمل را با سنتز منابع با استفاده از یک مجموعه آموزش داده شده بردارهای پایه، انجام می‌دهد. در [۲۳] یک روش جداسازی، با ترکیب روش NMF و مدل‌سازی منابع ارائه شده است. در واقع روش موجود به‌منظور حل پیچیدگی انتخاب بهینه بردارهای پایه در مرحله آموزش، ارائه شده است. در روش NMF اطلاعات فاز، مورد استفاده قرار نمی‌گیرد و تنها با استفاده از ماتریس طیف عمل جداسازی انجام می‌گیرد؛ اما در روش ارائه شده در [۲۳] این مسأله مورد بررسی قرار گرفته است.

۲-۴- مدل‌سازی منبع

در روش مدل‌سازی منبع برای جداسازی منابع، از یک مدل پارامتری برای هر منبع استفاده می‌شود. پارامترهای مدل برای هر منبع از مخلوط‌های مشاهده شده تخمین زده می‌شود. جدا کردن سیگنال‌ها به‌وسیله تولید سیگنال از مدل هر منبع، و یا به‌وسیله فیلتر کردن سیگنال مخلوط با فیلتری که توسط مقادیر پارامترهای مدل منبع کنترل می‌شود، صورت می‌پذیرد.

یکی از روش‌های اولیه مدل‌سازی منابع، روش انتخاب هارمونیک است که توسط Parsons ارائه شده است. در این روش یک مدل هارمونیک برای گفتار صدا دار فرض می‌شود. همچنین در این

¹Supervised

²Unsupervised

روش، الگوریتم تخمین و ردیابی گام^۱ بر پایه برداشتن قله‌های طیف، استفاده می‌شود. الگوریتم پیشنهادی با حذف هارمونیک‌های مربوط به گوینده تداخل کننده در حوزه زمان-فرکانس و بازسازی هارمونیک‌های گوینده مورد نظر در حوزه زمان، سیگنال گفتار دوگوینده را از یکدیگر جدا می‌سازد. نتایج به دست آمده نشان دهنده عملکرد خوب این روش بوده؛ اما این روش با آزمون شنوایی معمول ارزیابی نگردیده است.

تکنیک حذف دامنه هارمونیک (HMS)^۲ بیان شده توسط Hanson و Wong نیز استراتژی‌هایی شبیه روش قبل دارد. در این روش پارامترهای هارمونیک‌های گفتار تداخلی حدس زده می‌شوند. در واقع در یک سری موقعیت‌های عملی قوی‌تر از گفتار هدف، تخمین زده می‌شوند. سپس هارمونیک‌های سیگنال تداخلی از سیگنال مخلوط کم می‌شود تا سیگنال گفتار گوینده هدف بازسازی شود. Morgan در [۲۴] با به کارگیری تخمین گر گام ML [۱۲] این تکنیک را بهبود داده است. همچنین با به کارگیری یک مرحله بهسازی باعث بهبود هارمونیک‌ها و فورمنت^۳‌های گوینده هدف شده است.

Stubbs و Summerfield دو روش جداسازی گفتار بر پایه مدل هارمونیک را مورد ارزیابی قرار داده‌اند [۲۵]: (۱) فیلتر کپسترال^۴، و (۲) تکنیک ترکیبی که در آن، روش فیلتر کپسترال با انتخاب هارمونیک ترکیب شده است. در روش فیلتر کپسترال، کپستروم^۵ مخلوط دو سیگنال گفتار دارای پیک‌هایی در محل گام دو گفتار است. با حذف یکی از پیک‌ها می‌توان عمل جداسازی دو گوینده را انجام داد. در روش هیبرید [۲۶]، انتخاب هارمونیک برای بالا بردن کیفیت جداسازی در هنگامی که گفتار هدف بی‌صدا و گفتار تداخلی صدادار است، به فیلتر کپستروم اضافه می‌شود. این الگوریتم جداسازی بر روی انسان با شنوایی نرمال و سمع‌دار، ارزیابی شده است. عملکرد هر دو سیستم

¹Pitch

²Harmonic Magnitude Suppression

³Formants

⁴Cepstral Filter

⁵Cepstrum

هنگام ارزیابی با سیگنال‌های گفتار با گام تک‌تن، خوب بوده است. اما هنگامی که با سیگنال‌های گفتار نرمال ارزیابی شده، تنها روش فیلتر کپستروم و تنها برای انسان با سیستم شنوایی نرمال به‌خوبی کار کرده است.

با توجه به نظرات Hu و Wang در [۲۷]، مشکل اصلی برای همه روش‌های ذکر شده، عدم توانایی آن‌ها در برخورد با قسمت‌های فرکانس بالای گفتار است. چنانچه یک هارمونیک یک جزء غالب در یک کانال بانک فیلتر باشد، آن را قابل تفکیک می‌نامند؛ در غیر این صورت، آن هارمونیک غیرقابل تفکیک نامیده می‌شود. برای بانک فیلتر شنوایی استفاده شده روش Hu و Wang، فرکانس‌های پایین قابل تفکیک و فرکانس‌های بالا غیر قابل تفکیک می‌باشند. در این روش پارامترهای هارمونیک‌های قابل تفکیک به‌وسیله تجزیه AM-FM کانال بانک فیلتر مربوطه، تخمین زده می‌شوند. همچنین مدولاسیون دامنه هارمونیک‌های غیر قابل تفکیک برای تخمین پارامتر آن‌ها مورد ارزیابی قرار می‌گیرند. هارمونیک‌های تخمین زده شده برای گوینده‌های متفاوت بر اساس پیوستگی زمانی، همبستگی متقابل و مدولاسیون دامنه برچسب‌گذاری می‌شوند.

تعدادی از روش‌های جداسازی، منابع را به‌صورت یک مدل سینوسی کلی، مدل‌سازی می‌نمایند [۲۸]. در اغلب این روش‌ها یک محدودیت هارمونیک برای بهبود عملکرد تخمین پارامترها، به مدل سینوسی اضافه می‌شود. روش بازسازی منابع جدا شده در تکنیک مدل‌سازی سینوسی مشکل می‌باشد. در این روش برای بازسازی سیگنال جدا شده، یک بانک از نوسان‌سازهای متغیر با زمان با پارامترهای دامنه، فرکانس و فاز هارمونیک‌های منبع سیگنال جدا شده، استفاده می‌شوند.

همانطور که بیان کردیم هدف از این پایان نامه، جداسازی گفتار تک‌میکروفون می‌باشد. در قسمت اول این فصل، به بیان راه‌حل‌های موجود برای جداسازی دو گوینده پرداختیم. همانطور که بیان شد، در روش فیلتر فضایی حداقل نیاز به دو میکروفون می‌باشد. همچنین این روش قادر به جداسازی سیگنال‌های رسیده به میکروفون‌ها از یک مسیر نمی‌باشد.

روش‌های موجود برای جداسازی منابع صوتی در شرایط تک‌میکروفونه، به دو دسته کلی روش‌های بر پایه ویژگی^۱ و روش‌های بر پایه مدل‌سازی^۲ تقسیم می‌شوند. در روش‌های بر پایه مدل‌سازی، هر کدام از سیگنال‌های هدف و تداخل با استفاده از مدل‌های آماری، مدل می‌شوند. مدل به کار رفته برای جداسازی دو گوینده مورد استفاده قرار می‌گیرد. مشکل این روش برخورد با تداخل‌های جدید است زیرا که برای سیگنال‌های تداخلی جدید مدلی در نظر گرفته نشده است. همچنین در این روش، برای مدل‌سازی سیگنال‌های هدف و تداخل نیاز به داده‌هایی تمیز از هر دو سیگنال داریم. در روش بر پایه ویژگی، با توجه به ویژگی‌های موجود در سیگنال گفتار و نیز با توجه به سیستم شنوایی انسان، عمل جداسازی انجام می‌گیرد. در ادامه به بررسی روش‌های بر پایه ویژگی موجود برای جداسازی گفتار تک‌میکروفونه می‌پردازیم.

۲-۵- روش‌های بر پایه ویژگی

همانطور که می‌دانیم انسان در محیطی زندگی می‌کند که در برگیرنده منابع متعدد صوتی بوده و بنابراین صدای رسیده به گوش انسان، ناشی از چندین منبع صوتی است. در حالی که موضوع بهسازی گفتار با استفاده از یک میکروفون یک موضوع بحث برانگیز شده است، سیستم شنوایی انسان توانایی قابل توجهی را برای جداسازی گفتار از خود نشان داده است. بر همین اساس، Bregman در سال ۱۹۹۴ سیستم جداسازی شنوایی را با عنوان ASA در [۵] مطرح کرد. با الهام گرفتن از اصول ASA، سیستم محاسباتی ASA برای جداسازی گفتار ارائه شد. این سیستم که CASA نامیده شد، بدون استفاده از فرضیات در خصوص خواص گفتار و تداخل و تنها با استفاده از اصول ادراکی و خواص ذاتی صدا مانند هارمونیک بودن^۳، فراز، فرود، محل منبع صدا^۴ و اطلاعات قبلی^۵ از صداها، عمل

^۱Feature-Based

^۲Model-Based

^۳Harmonicity

^۴Location

^۵Prior knowledge

جداسازی گفتار را انجام می‌دهد. در ادامه به بررسی کامل سیستم CASA و روش‌های موجود در این زمینه می‌پردازیم.


۲-۵-۱- روش‌های CASA

سیستم‌های CASA به‌طور گسترده برای جداسازی منابع گفتاری به کار برده می‌شوند. در سیستم CASA مجموعه‌ای وسیع از پیاده‌سازی محاسباتی سیستم آنالیز شنوایی (ASA) به کار برده می‌شود. قبل از توصیف سیستم CASA، ابتدا به بررسی سیستم آنالیز شنوایی و کاربردهای اصلی آن می‌پردازیم. بسیاری از دانشمندان عقیده دارند که سیستم شنوایی و بینایی بسیار به یکدیگر شباهت دارند. سیستم شنوایی گفتار را به سیستم عصبی منتقل نموده و در مغز عملیات پردازشی شبیه پردازش تصویر بر روی آن انجام می‌شود. کلیه عملیات سیستم شنوایی را می‌توان به دو مرحله دسته‌بندی نمود: بخش‌بندی و گروه‌بندی. در مرحله اول، ابتدا گفتار به فضای دو بعدی زمان-فرکانس برده می‌شود و سپس واحدهای زمان-فرکانس شبیه به یکدیگر در یک بخش یا ناحیه قرار داده می‌شوند و به این ترتیب کل فضای زمان-فرکانس بخش‌بندی می‌شود. در مرحله دوم، بخش‌ها بر اساس ویژگی‌های آکوستیکی و دیگر اطلاعات، به دسته‌های متفاوتی گروه‌بندی می‌شوند. در نهایت سیگنال گفتار هدف و یا تداخل و یا هر دوی آن‌ها برای اهداف گوناگون بازسازی می‌شوند.

به‌طور کلی سیستم CASA از روش‌های محاسباتی برای تولید یک سیستم ادراکی ماشینی شبیه سیستم شنوایی انسان، استفاده می‌کند. Wang و Brown در [۹]، CASA را زمینه مطالعاتی محاسباتی تعریف کردند که هدف آن به‌دست آوردن کارایی انسان در ASA، به‌وسیله یک یا دو میکروفون ضبط صدا است.

شکل (۲-۶) بلوک دیاگرام ساده‌ای از سیستم CASA را نشان می‌دهد. در ابتدا سیگنال گفتار وارد مرحله تابع تبدیل می‌گردد. در اغلب موارد، این تابع، سیگنال گفتار تک‌بعدی زمان را به‌صورت نمایش دو بعدی معروف زمان-فرکانس تبدیل می‌نماید. این انتقال توسط روش استاندارد تبدیل فوریه زمان

کوتاه^۱ (STFT) و یا فیلتربانک گاماتون^۲ (که از مشاهدات روان-آکوستیکی^۳ محیط شنیداری به دست آمده، مدلی استاندارد از گوش درونی است [۲۹]) صورت می گیرد. در مرحله بعد همه واحدهای زمان-فرکانس به ناحیه‌هایی متفاوت بخش‌بندی می‌شوند. همه واحدهای زمان-فرکانس قرار گرفته شده در یک ناحیه، مربوط به یک منبع گفتار می‌باشند. الگوریتم‌های استخراج ویژگی متفاوتی در این مرحله برای بهینه‌سازی نتایج بخش‌بندی، ارائه شده است. در مرحله آخر، بخش‌های به دست آمده در مرحله قبل، گروه‌بندی می‌شوند. این مرحله بر اساس فرمت گفتار^۴، به منظور استخراج بخش‌های مربوط به منبع گفتار هدف و حذف دیگر بخش‌ها پردازش می‌شود. یکی از معمول‌ترین روش‌های به کار رفته در مرحله آخر، شناسایی گوینده^۵ است. در نهایت همه واحدهای زمان-فرکانس استخراج شده، برای بازسازی و سنتز گفتار هدف به کار برده می‌شوند.



شکل (۲-۶) بلوک دیاگرام ساده‌ای از سیستم CASA [۶]

سیگنال گفتار، سیگنالی است که هم در بعد زمان و هم در بعد فرکانس، دارای محدوده دینامیکی بالایی می‌باشد. این ساختار غیرایستایی^۶ گفتار باعث می‌گردد که بازشناسی و جداسازی گفتار در حضور سیگنال تداخلی گفتار دیگر، عملی پیچیده و مشکل گردد. به همین دلیل است که در سیستم‌های CASA به مسأله تصویر سیگنال گفتار یک بعدی به ابعاد بالاتر، توجه زیادی شده است. در خیلی از اوقات سیگنال گفتار تخریب شده به وسیله تداخل، در حوزه زمان-فرکانس به دلیل پراکندگی انرژی^۷ در این حوزه، قابل جداسازی از سیگنال تداخلی است. برای درک این موضوع با

^۱Short Time Fourier Transform

^۲Gammatone Filterbank

^۳Psychoacoustic Observations

^۴Utterance-Based Format


^۵Speak Identification

^۶Nonstationary

^۷Energy Sparsity

بررسی اسپکتروگرام سیگنال گفتار به راحتی می توان دید که همه واحدهای زمان-فرکانس نقش مهمی در نمایش اطلاعات مربوط به گفتار ندارند. درصد بالایی از واحدهای زمان-فرکانس، دارای انرژی کم و بسیار کم اهمیت تر از درصد کمی از واحدها هستند که دارای انرژی زیادی می باشند. تبدیل زمان-فرکانس باعث کاهش ابهام سیگنال گفتار نسبت به قبل از تبدیل می گردد. در نتیجه واحدهای زمان-فرکانس که کمتر به وسیله سیگنال گفتار تداخلی مورد تخریب قرار گرفته اند، به عنوان واحدهایی پایه، برای بازسازی سیگنال گفتار هدف مورد استفاده قرار می گیرند.

با توجه به مزایای تصویر دو بعدی، تئوری دو مرحله ای ASA می تواند به مسأله جداسازی منابع کمک زیادی نماید. شکل (۷-۲) شماتیک ساده ای را جهت اثبات این تئوری نشان می دهد. در شکل (۷-۲) a- ناحیه های زمان-فرکانس بدست آمده به علت نزدیک بودن به یکدیگر در محور فرکانس، در یک گروه دسته بندی می شوند؛ این در حالی است که در شکل (۷-۲) b- ناحیه هایی که در محور فرکانس از یکدیگر دور می باشند در دو گروه جدا از هم دسته بندی شده اند [۹،۳۰].



شکل (۷-۲) شماتیک ساده ای از روش گروه بندی ناحیه های به دست آمده در حوزه زمان-فرکانس در روش های CASA. (a) گروه بندی ناحیه ها در یک دسته، به علت نزدیکی ناحیه ها در محور فرکانس. (b) گروه بندی ناحیه ها در دو دسته، به علت دوری ناحیه ها در محور فرکانس [۹،۳۰].

۲-۵-۱-۱- مروری بر روش های CASA برای جداسازی گفتار تک میکروفونه

بیشتر سیستم های CASA به منظور جداسازی سیگنال گفتار از سیگنال تداخلی، توسعه یافته اند. تنها هدف تعداد محدودی از این سیستم ها، جداسازی انواع دیگر صداها است؛ مانند سیستم Mellinger که برای جداسازی موزیک و سیستم Wang و Li که برای جداسازی آواز از موزیک است.

همانطور که بیان شد سیستم‌های CASA در ابتدا با استفاده از فیلتربانک، سیگنال را از حوزه زمان به فضای زمان-فرکانس منتقل می‌کنند. خروجی آنالیز اولیه سیستم CASA (خروجی فیلتربانک)، برای استخراج ویژگی‌هایی متناسب با ASA به کار برده می‌شود. بسیاری از سیستم‌های CASA برای جداسازی گفتار تک‌میکروفونه، بر روی جداسازی گفتار صدادار^۱، با استفاده از ویژگی تناوب، تمرکز یافته‌اند. بهترین نمایش برای آنالیز تناوب، همبستگی نگاشت^۲ است که در بسیاری از سیستم‌های CASA به کار گرفته می‌شود. همبستگی نگاشت، نشان‌دهنده خودهمبستگی سیگنال‌های هر کانال از بانک فیلتر در محدوده زمانی یک دوره است. تناوب سیگنال به وسیله تابع خودهمبستگی^۳ (ACF) نمایش داده می‌شود [۳۱].

جداسازی گفتار در حضور نویز و سایر تداخل‌ها، یکی از مسائل چالش برانگیز به‌ویژه در مورد جداسازی تک‌میکروفونه می‌باشد. گرچه پیشرفت‌های قابل ملاحظه‌ای در زمینه‌ی جداسازی گفتار صدادار به دست آمده است، با این وجود عملکرد سیستم‌های جداسازی CASA در بخش‌های فرکانس بالا مناسب نیست. پس برچسب‌گذاری دقیق واحدها در هر دو ناحیه‌ی فرکانس پایین و بالا می‌تواند تاثیر قابل توجهی در نتایج جداسازی داشته باشد. در [۳۲] روش‌های جدیدی برای برچسب‌گذاری واحدهای زمان-فرکانس^۴ پیشنهاد می‌شود. به بیان دقیق‌تر، در مرحله‌ی جداسازی اولیه، برای انتخاب واحدهای زمان-فرکانس، همبستگی بین کانالی پوش پاسخ در تمام فرکانس‌ها به کار رفته است. همچنین، در مرحله ردیابی گام و برچسب‌گذاری واحدها در فرکانس‌های بالا، از تابع خودهمبستگی پوش بهبودیافته^۵ (EEACF) برای حذف پیک‌های نادرست و یا مضارب پیک اصلی از منحنی تابع خودهمبستگی پوش^۶ (EACF)، استفاده شده است که نشان‌دهنده نتایج بهتر جداسازی نسبت به روش‌های معمول می‌باشد.

¹Voice Speech

²Correlogram


³Autocorrelation Function

⁴Time-Frequency (T-F) Units

⁵Enhanced Envelope Autocorrelation Function

⁶Envelope Autocorrelation Function

شکل (۸-۲) نمونه‌ای از همبستگی نگاشت را برای سیگنال گفتار مرد با طول ۰.۷ ثانیه نشان می‌دهد. هر کدام از نمودارهای نشان داده شده برای هر فرکانس، ACF به‌دست آمده برای سیگنال باند باریک مربوط به کانال فیلتربانک با همان فرکانس را نشان می‌دهد. ماکزیمم‌های نمودارهای ACF، دوره تناوب سیگنال مربوطه را نشان می‌دهد. با توجه به این که سیگنال گفتار در طول این بازه زمانی صددار است، همه نمودارهای ACF، ماکزیمم‌هایی را در تأخیر ۵.۸۷ میلی‌ثانیه نشان می‌دهد که بیانگر دوره تناوب سیگنال گفتار در آن بازه زمانی است.



شکل (۸-۲) (a) نمودار گوینده مرد در حوزه زمان-فرکانس. (b) شکل موج گوینده مرد. (c) همبستگی نگاشت برای سیگنال گوینده مرد با طول ۰.۷ ثانیه. پانل پایینی همبستگی نگاشت مختصر و پانل سمت راست تابع همبستگی متقابل بین کانال‌ها را نشان می‌دهد [۶].

این مسأله باعث ایجاد انگیزه‌هایی برای ایجاد الگوریتم تعیین گام به‌وسیله نمودارهای ACF گردیده که همبستگی نگاشت مختصر^۱ نامگذاری شده‌اند. همبستگی نگاشت مختصر برابر مجموع نمودارهای ACF در همبستگی نگاشت بر روی محور فرکانس است که در پایین شکل (۸-۲) نشان داده شده است. ماکزیمم به‌دست آمده در همبستگی نگاشت مختصر، دوره تناوب سیگنال گفتار را نشان می‌دهد. در سال ۱۹۸۵ Weintraub، روشی برای جداسازی دو گوینده همزمان زن و مرد ارائه

^۱Summary Correlogram

کرد [۳۳]. در سیستم پیشنهادی وی، ابتدا نمودار گام هر گوینده، تخمین زده شده و سپس با تخمین دامنه‌های طیف هر منبع، سیگنال گفتار بر اساس تناوب و پیوستگی زمانی، دو سیگنال گفتار از یکدیگر جدا می‌شوند. سیستم جداسازی Weintraub شامل سه مرحله به شرح زیر است:

در مرحله اول، نمودارهای گام مربوط به هر گوینده تخمین زده می‌شود. در این مرحله، سیستم از تابع خودهمبستگی برای پیدا کردن تناوب سیگنال استفاده می‌کند. بر اساس این تابع، سیستم یک گام غالب در هر فریم زمانی به طول ۱۰ میلی ثانیه را معین می‌کند. گام غالب ممکن است به هر یک از دو گوینده تعلق داشته باشد. گام غالب با اطلاع از این که یک گوینده مرد و دیگری زن است، به گوینده صحیح نسبت داده می‌شود. با استفاده از گام غالب، سیستم نمودار گام هر گوینده را بر اساس پیوستگی زمانی نمودارهای گام ردیابی می‌نماید. خروجی این مرحله دو دوره تناوب تخمین زده شده در هر فریم زمانی است، بدون توجه به این که گفتار مربوطه کجا صدادار، بی‌صدا و یا سکوت است.

در مرحله دوم سیستم نوع سیگنال گفتار را برای هر گوینده تعیین می‌کند. Weintraub در سیستم پیشنهادی خود هفت نوع سیگنال گفتار را مورد بررسی قرار می‌دهد: سکوت، متناوب، غیر متناوب، فراز، فرود، افزایش به سمت تناوب^۱ و کاهش یافتن تناوب^۲. یک مدل مارکف برای مدل سازی رابطه ترتیبی انواع سیگنال گفتار، هنگامی که دو گوینده همزمان وجود داشته باشد، آموزش داده می‌شود. گام و دامنه سیگنال گفتار ویژگی‌هایی است که برای آموزش مدل مارکف به کار برده می‌شود. سیستم Weintraub بر پایه مدل مارکف، الگوریتم ویتربی را برای تعیین نوع سیگنال گوینده در هر فریم زمانی به کار می‌برد. خروجی این مرحله، باعث ایجاد توصیف دقیق تری از نوع سیگنال گفتار در هر فریم زمانی می‌گردد. در نتیجه دوره‌های گام تخمین زده شده برای فریم‌هایی که سیگنال گفتار در آن‌ها متناوب نیست، حذف می‌گردند.

¹Increasing Periodicity

²Decreasing Periodicity

در مرحله سوم، با تخمین دامنه طیف مربوط به هر منبع صدا، با توجه به دوره گام و نوع گفتار برای هر گوینده، عمل جداسازی دو گوینده همزمان انجام می‌گیرد. در نهایت دامنه طیف تخمین زده شده برای بازسازی سیگنال گفتار هدف، مورد استفاده قرار می‌گیرد.

محاسبه دوره گام در سیستم Weintraub بر این اساس بود که دوره گام گوینده زن از دوره گام گوینده مرد بالاتر است. به همین دلیل در سیستم Weintraub امکان جداسازی دوگوینده همزمان مرد و یا زن وجود نداشت. به‌طور کلی این سیستم تنها برای جداسازی گفتار دو گوینده زن و مرد طراحی گردیده بود و قادر به جداسازی سیگنال گفتار از دیگر سیگنال‌های تداخلی (غیر از سیگنال گفتار) نبود.

در سال ۱۹۹۳، Cooke توانست اولین سیستم جداسازی سیگنال گفتار از انواع سیگنال‌های تداخلی را ارائه نماید [۳۴]. سیستم پیشنهادی او، ابتدا سیگنال مخلوط از فیلتربانک را عبور داده و سپس فرکانس لحظه‌ای مربوط به هر سیگنال باند باریک به‌دست آمده از هر کانال فیلتربانک را محاسبه می‌کند. کانال‌های مجاور با یکدیگر در هر فریم زمانی که دارای تغییرات آرام فرکانس لحظه‌ای در طول کانال‌ها هستند، در کنار یکدیگر گذاشته می‌شوند. این کانال‌های کنار هم گذاشته شده، شامل یک یا چند هارمونیک از یک منبع صدا هستند. کانال‌های کنار هم گذاشته در طول فرکانس، در فریم‌های زمانی مجاور نیز به یکدیگر متصل شده و بخش‌ها را به‌وجود می‌آورند. بخش‌هایی که با یکدیگر همپوشانی داشته باشند و دارای فرکانس گام یکسان باشند، تشکیل یک گروه می‌دهند. در نهایت نمودارهای گام برای هر گروه تخمین زده شده و گروه‌هایی که دارای نمودارهای گام یکسان باشند، در یک رشته قرار می‌گیرند که هر رشته مربوط به یک منبع صدا می‌باشد.

یک مجموعه داده‌های گفتاری توسط Cooke برای ارزیابی عملکرد سیستم جداسازی گفتار تک‌میکروفون تهیه گردیده است. این مجموعه شامل ۱۰ صدای گفتار زن و مرد و ۱۰ نمونه سیگنال تداخلی است. با استفاده از سیگنال‌های این مجموعه می‌توان ۱۰۰ نمونه سیگنال مخلوط با نسبت

سیگنال به نویز^۱ (SNR) مختلف تهیه نمود. سیگنال‌های تداخلی که تنوع بسیاری نیز دارند، عبارتند از: ۱- تک‌تن^۲ با فرکانس 1kHz، ۲- نویز سفید، ۳- نویز ضربه‌ای^۳، ۴- نویز همهمه، ۵- موزیک rock، ۶- سوت کارخانه، ۷- زنگ تلفن، ۸- گفتار زن، ۹- گفتار مرد، ۱۰- گفتار زن. این مجموعه همچنین برای ارزیابی دیگر سیستم‌های جداسازی گفتار نیز به کار رفته است [۳۳، ۳۴، ۳۵].

در ارزیابی عملکرد سیستم جداسازی گفتار Cooke، به‌طور میانگین ۷۰٪ از سیگنال گفتار جدا شده مربوط به گفتار هدف و در حدود ۱۰٪ از آن مربوط به سیگنال تداخلی است. سیستم Cooke، گفتار صدادار در فرکانس‌های پایین را بهتر از فرکانس‌های بالا جداسازی می‌نماید. در واقع این سیستم حتی در زمانی که سیگنال تداخلی نیز وجود نداشته باشد، قادر به بازسازی بسیاری از قسمت‌های هدف در فرکانس بالا نمی‌باشد.

در سال ۲۰۰۵، Brown و Cooke سیستم جداسازی تک‌میکروفون قبلی را بهبود دادند [۳۵]. هدف از مدل پیشنهادی، تخمین یک ماسک زمان-فرکانس باینری برای گفتار هدف بود. گفتار هدف با به‌کارگیری ماسک و سنتز آن به‌وسیله روش سنتز Weitraub بازسازی می‌گردد [۳۳]. این سیستم پیشنهادی در بسیاری از جهات متفاوت از سیستم Cooke است. در این سیستم همبستگی نگاشت برای نمایش تناوب محاسبه می‌گردد. برای بخش‌بندی فضای زمان-فرکانس در این سیستم، کانال‌های همسایه بر اساس تابع همبستگی متقابل بین کانال‌ها با یکدیگر ادغام می‌شوند.

تابع همبستگی متقابل شباهت بین تابع خودهمبستگی کانال‌های مجاور را با یکدیگر مقایسه می‌کند. تابع خودهمبستگی متقابل بالاتر نشان‌دهنده شباهت بیشتر بین دو کانال مجاور است. یک نمونه از تابع همبستگی متقابل در شکل (۲-۸) نمودار سمت راست نشان داده شده است. همانطور که در شکل نشان داده شده، کانال‌های همسایه‌ای که دارای محتوای فرکانسی یکسان می‌باشند (هارمونیک سیگنال گفتار)، دارای تابع خودهمبستگی مشابه بوده و در نتیجه تابع همبستگی متقابل

¹Signal-to-Noise Ratio

²Pure Tone

³Noise Bursts

آن‌ها زیاد می‌باشد. در نتیجه در این سیستم بر اساس تابع همبستگی متقابل، کانال‌هایی که دارای محتوای فرکانسی یکسان هستند، با یکدیگر ادغام می‌شوند. کانال‌های ادغام شده در فریم‌های زمانی پشت سر هم بر اساس پیوستگی زمانی به یکدیگر متصل شده و تشکیل بخش می‌دهند. برای گروه‌بندی، سیستم ابتدا نمودار گام هر بخش را با استفاده از تابع خودهمبستگی تخمین می‌زند. سپس بخش‌های دارای نمودار گام یکسان را در یک رشته، گروه‌بندی می‌کند. همچنین در این سیستم از ویژگی‌های فراز و فرود برای گروه‌بندی بخش‌ها استفاده می‌شود [۹،۳۵].

برای ارزیابی سیستم Brown و Cooke از مجموعه داده‌های Cooke استفاده شده و نتایج شبیه نتایج سیستم Cooke به دست آمد. در این سیستم مقدار زیادی از انرژی سیگنال تداخلی از رشته به دست آمده برای سیگنال هدف حذف گردید؛ اما مقدار قابل توجهی از انرژی سیگنال هدف، به خصوص در فرکانس‌های بالا نیز در سیگنال هدف جدا شده، از بین رفته است. نتایج ارزیابی نشان می‌دهد که به کارگیری ویژگی‌های اضافی فراز و فرود برای گروه‌بندی نیز نتوانسته باعث بهبود قابل توجهی در عملکرد سیستم شود.

در سال ۱۹۹۱، Wang و Brown یک سیستم CASA شبیه سیستم Brown و Cooke پیشنهاد دادند. تفاوت اصلی میان این دو سیستم این است که در سیستم Wang و Brown از یک شبکه نوسان‌ساز دو لایه برای جداسازی گفتار استفاده شده است. در اولین لایه، بخش‌ها براساس تابع همبستگی متقابل و پیوستگی زمانی تشکیل می‌شوند. در هر فریم زمانی واحدهای زمان-فرکانس همسایه در صورتی در بخش‌ها با یکدیگر ادغام می‌شوند که تابع همبستگی متقابل آن‌ها از یک حد آستانه بالاتر باشد. به عبارت دیگر، دو واحد زمان-فرکانس در یک کانال و در دو فریم مجاور در صورتی با یکدیگر ادغام می‌شوند که تابع خود همبستگی متقابل میان آن دو واحد بالاتر از حد آستانه باشد. در لایه دوم شبکه Wang و Brown با استفاده از گام کلی تخمین زده شده در هر فریم زمانی، بخش‌ها در دو رشته، یکی برای سیگنال هدف و دیگری برای تداخل، گروه‌بندی می‌شوند. برای تخمین گام کلی، ابتدا سیستم بزرگ‌ترین بخش را به عنوان بخش پایه پیدا می‌کند. سپس سیستم

فریم‌های هر بخش را که تناوب گام آن‌ها با تناوب گام کلی بخش پایه یکی است، تعیین می‌نماید. اگر تناوب گام بیش از نیمی از فریم‌های بخش با بخش پایه یکی باشد، آن بخش با بخش پایه در یک رشته قرار داده می‌شود. در غیر این صورت، این بخش در رشته دیگر گذاشته می‌شود. با وجود این که سیستم Wang و Brown از لحاظ محاسباتی ساده‌تر از سیستم Brown و Cooke بود، اما دارای عملکردی شبیه به آن بود [۹].

علاوه بر سیستم‌های بالا، مطالعات زیادی در زمینه CASA برای جداسازی گفتار تک‌میکروفون انجام گرفته است. در بسیاری از این سیستم‌ها نیز از ویژگی هارمونیک گفتار برای جداسازی استفاده گردیده است. به عنوان مثال، Parsons سیستمی را برای جداسازی دو گوینده همزمان به وسیله نمودارهای گام دو گوینده از روی طیف سیگنال مخلوط پیشنهاد کرد که در آن هارمونیک‌های گفتار هدف با توجه به نمودارهای گام تخمین زده شده انتخاب می‌شوند [۳۶]. چندین روش برای جداسازی دو صدای همزمان، بر اساس تناوب سیگنال، با هدف مدل‌سازی رفتار سیستم شنوایی انسان ارائه شده است. علاوه بر تناوب، دیگر ویژگی‌های ASA نیز در سیستم‌های جداسازی گفتار به کار گرفته شده است. Abe و Ando سیستمی بر مبنای مدولاسیون فرکانس و دامنه برای جداسازی گفتار ارائه کردند. Masuda-Katsuse و Kawahara یک سیستم CASA پیشنهاد دادند که در آن برای منابع صوتی متفاوت، رشته‌هایی با توجه به ردیابی تغییرات در شکل طیف، تولید می‌نمایند.

برخی از پژوهش‌ها برای جداسازی گفتار دو گوینده همزمان، از مدل‌های وابسته به گوینده‌ی از پیش آموزش داده شده^۱، استفاده می‌کنند. در [۳۷]، یک روش بدون نظارت برای جداسازی گفتار دو گوینده پیشنهاد داده شده است. روش موجود دو مرحله اصلی CASA (آنالیز ترکیب شنیداری محاسباتی) را دنبال می‌کند: مرحله اول، بخش‌بندی^۲ نامیده شده که ترکیب شنیداری را به عناصر (یا بخش‌های) حسی تجزیه می‌کند؛ به طوری که هر یک از آن‌ها مربوط به یک منبع یکتا باشد. مرحله دوم، گروه‌بندی نامیده شده و در آن بخش‌های مربوط به یک منبع در یک گروه قرار می‌گیرند.

¹Pretrained

²Segmentation

در [۳۷]، سیستم پیشنهادی به منظور جداسازی گفتار صدادار^۱، از یک الگوریتم tandem [۳۸]، برای گروه‌بندی همزمان و سپس خوشه‌بندی^۲ بدون نظارت برای گروه‌بندی متوالی استفاده می‌کند. به منظور جداسازی گفتار بی‌صدا^۳، در مرحله اول بخش‌های گفتار بی‌صدا مبتنی بر تجزیه و تحلیل فراز-فرود تولید می‌شوند. بخش‌های گروه‌بندی شده با استفاده از ماسک‌های باینری مکمل^۴ گفتار صدادار جدا می‌شوند. در واقع صداها همزمان توسط ماسک باینری ایده آل^۵ (IBM) تخمین زده می‌شوند [۹]. یک ماسک IBM، با استفاده از یک SNR محلی^۶ به دست می‌آید. به طور خاص، به یک واحد زمان-فرکانس (T-F) که سیگنال هدف در آن غالب است، عدد یک و به غیر آن، عدد صفر نسبت داده می‌شود [۳۹]. ارزیابی اصولی و مقایسه‌ها نشان می‌دهند که این روش با وجود بدون نظارت بودن، عملکرد قابل توجهی در مقایسه با روش‌های مبتنی بر مدل و وابسته به گوینده داشته است.

همچنین در سال ۲۰۱۳، Wang و Hu علاوه بر مقاله [۳۷]، یک روش با نظارت را نیز برای جداسازی دو گوینده همزمان ارائه دادند. در این روش مشخصات دو گوینده داده شده است. در روش-های مبتنی بر مدل، عدم تطابق بین ترازهای آموزش^۷ و تست^۸ سیگنال وجود دارد. به همین منظور در [۴۰] توسط یک الگوریتم تکراری^۹ به منظور تطابق مدل‌های گفتار با ترازهای سیگنال در مرحله تست ارائه شده است. این الگوریتم در مرحله اول، تخمین‌های اولیه منبع سیگنال را با استفاده از مدل‌های گفتار HMM نامنطبق به دست می‌آورد، سپس SNR ورودی از صدای مخلوط را تشخیص می‌دهد. SNR ورودی به منظور تطابق مدل‌های گفتار برای تخمین درست استفاده شده است. از مرحله دوم به بعد که نسبت سیگنال به نویز به عدد خاصی همگرا می‌شود، این الگوریتم تکرار می‌شود. بعد از این

¹Voiced Speech

²Clustering

³Unvoiced Speech

⁴Complementary Binary Masks

⁵Ideal Binary Mask

⁶Local SNR

⁷Training

⁸Test


⁹Iterative Algorithm

مرحله ماسک‌های باینری مناسب برای جداسازی دو گوینده همزمان به‌دست می‌آید. مقایسه‌ها نشان می‌دهند روش پیشنهادی عملکرد خوبی در مقایسه با روش‌های مبتنی بر مدل داشته است.

۲-۵-۲- آنالیز مدولاسیون و فیلتر نمودن

سیگنال‌های طبیعی مانند گفتار و موزیک را می‌توان توسط سیگنال مدولاتور فرکانس پایین که سیگنال حامل فرکانس بالا را مدوله کرده است، نمایش داد [۴۱]. این مفهوم به‌وسیله اسپکتروگرام یک نمونه سیگنال گفتار که در شکل (۹-۲) نشان داده شده است، قابل توصیف می‌باشد. طیف نشان داده شده در شکل، توزیع انرژی سیگنال را در فضای زمان-فرکانس نشان می‌دهد. رنگ روشن نشان‌دهنده نقاطی با انرژی کم و رنگ تیره برای نقاطی با انرژی زیاد است.

همانطور که اسپکتروگرام سیگنال نشان می‌دهد، بیشتر انرژی سیگنال در خطوط افقی متمرکز شده‌اند که دارای فاصله مساوی در طول محور فرکانس است. هر کدام از این خطوط افقی مربوط به یکی از هارمونیک‌های سیگنال گفتار می‌باشد. سیگنال‌های جداگانه چهار هارمونیک اول در یک فریم زمانی کوتاه (به‌وسیله یک مستطیل کوچک در پایین اسپکتروگرام نشان داده شده است) در پانل وسطی شکل (۹-۲) نشان داده شده است. با توجه به سیگنال‌های نشان داده شده برای هر هارمونیک، می‌توان فهمید که هر سیگنال از حاصل ضرب دو سیگنال حامل و پوش تشکیل شده است. حامل، یک سیگنال فرکانس بالا است که شامل ساختار زمانی سیگنال هارمونیک است و پوش، سیگنال فرکانس پایینی است که تغییرات آهسته آهسته سیگنال دامنه سیگنال هارمونیک را دنبال می‌کند. تجزیه هر سیگنال هارمونیک، به سیگنال حامل و پوش (یا سیگنال مدولاتور) در پانل سمت راست شکل (۹-۲) نشان داده شده است.



شکل (۲-۹) نمایش اسپکتروگرام سیگنال گفتار و چهار هارمونیک اول آن که به سیگنال‌های حامل و مدولاتور تجزیه شده است. پانل سمت چپ اسپکتروگرام سیگنال گفتار یک گوینده مرد برای بیان کلمه "seven" را نشان می‌دهد. پانل وسطی سیگنال چهار هارمونیک اول و پانل سمت راست سیگنال مدولاتور و حامل حاصل از تجزیه هر سیگنال هارمونیک را نشان می‌دهد [۴۱].

بسیاری از مطالعات نشان داده است که سیگنال مدولاتور در درک یک سیگنال گفتار بسیار با اهمیت است. به‌عنوان مثال، هنگامی که یک سیگنال مدولاتور، با یک مقدار ثابت جایگزین شود، گفتار غیر قابل درک می‌شود. در مقابل، اگر سیگنال حامل با یک نویز سفید جایگزین شود اما سیگنال مدولاتور دست نخورده باقی بماند، گفتار همچنان قابل درک است. اهمیت سیگنال مدولاتور در درک سیگنال گفتار سبب شد تا این سیگنال به‌عنوان یک ویژگی برای جداسازی منابع صدا، در شرایطی که تنها یک میکروفون در دسترس است، مورد استفاده قرار گیرد.

برای آنالیز و پردازش سیگنال مدولاتور، ابتدا سیگنال باند وسیع به‌وسیله فیلتربانک به سیگنال‌های باند باریک تجزیه می‌گردد. سپس هر سیگنال باند باریک به سیگنال‌های مدولاتور و حامل تجزیه

می‌شود. در نهایت با توجه به سیگنال مدولاتور به‌دست آمده، روش‌های استخراج ویژگی متفاوتی برای جداسازی منابع صوتی از یکدیگر مورد استفاده قرار می‌گیرد.

روش‌های موجود برای تخمین سیگنال مدولاتور به دو دسته طبقه‌بندی می‌شوند: ناهمدوس و همدوس. در روش ناهمدوس تخمین سیگنال مدولاتور یا پوش یک سیگنال باند باریک حقیقی با استفاده از تبدیل پوش هیلبرت^۱ و برای سیگنال باند باریک با مقدار مختلط، به‌وسیله عملگر تخمین دامنه^۲ انجام می‌گیرد. در روش همدوس ابتدا سیگنال حامل با استفاده از یک تخمین‌گر حامل^۳، بر اساس خواص فرکانس لحظه‌ای^۴ (IF) سیگنال تخمین زده شده و سپس با توجه به سیگنال حامل به‌دست آمده سیگنال مدولاتور تخمین زده می‌شود.

Schimmel الگوریتمی بر مبنای روش ناهمدوس برای جداسازی دو گوینده همزمان، در شرایطی که تنها یک میکروفون در دسترس است، پیشنهاد کرد [۴۱]. در این الگوریتم با فرض معلوم بودن محدوده گام هر گوینده و ثابت بودن آن در همه کانال‌های فرکانسی، یک ماسک برای جداسازی دو گوینده همزمان در فضای طیف مدولاسیون ارائه شده است. اما همانطور که می‌دانیم در شرایط واقعی و برای گوینده‌های متفاوت و ناشناس، این محدوده گام معین نمی‌باشد و باید توسط روش‌های موجود به‌منظور تخمین فرکانس گام دو گوینده همزمان، تخمین زده شود.

Won و دیگر همکارانش الگوریتمی بر اساس روش همدوس برای بهبود سیگنال نویزی در سمعک و کسانی که مشکل شنوایی دارند، ارائه کرده‌اند. در این روش، با به‌کارگیری فیلتر وقتی بر روی سیگنال مدولاتور به‌دست آمده از روش همدوس و با فرض دانستن سیگنال کانال مرجع (سیگنال نویز)، سیگنال نویزی بهبود می‌یابد؛ اما در شرایطی که تنها یک میکروفون و یک صدای ضبط شده در دسترس باشد، امکان دسترسی به سیگنال نویز وجود ندارد. در نتیجه الگوریتم پیشنهادی تنها در شرایطی قادر به بهسازی سیگنال نویزی است که سیگنال کانال مرجع در دسترس باشد [۴۲].

¹ Hilbert Envelope

² Magnitude Operator

³ Carrier Estimator

⁴ Instantaneous Frequency

در [۴۳] یک سیستم جداسازی تک میکروفونه بر پایه روش دمدولاسیون ناهمدوس ارائه شده که در آن ابتدا محدوده فرکانس گام یک، یا دو گوینده همزمان، تخمین زده می شود و سپس با استفاده از آن، گفتار هدف از تداخل جدا می شود. محدوده گام با استفاده از الگوریتم فراز و فرود و با توجه به توزیع انرژی گوینده ها در حوزه طیف دمدولاسیون، تخمین زده شده است. زمانی که گوینده های هدف و تداخل هر دو مرد و یا هر دو زن باشند، روش های تخمین فرکانس گام به دلیل نزدیکی فرکانس گام دو گوینده با خطای زیادی مواجه می شوند. در نتیجه سیستم های CASA که فرکانس گام را به عنوان یک ویژگی مهم در جداسازی گفتار به کار می برند، دچار مشکل می شوند. در مقابل یکی از نوآوری های مهم سیستم پیشنهادی، تخمین محدوده فرکانس گام دو گوینده همزمان، در فریم های زمانی کوچک است. در این سیستم همچنین ماسک تولید شده برای جداسازی، وابسته به محدوده گام تخمین زده شده در هر کانال فرکانسی می باشد. با توجه به نتایج به دست آمده، سیستم پیشنهادی قادر به جداسازی قسمت عمده قسمت های صدادر سیگنال گفتار هدف از سیگنال تداخلی است. علاوه بر این، قسمت هایی از گفتار بی صدا که به علت نزدیکی به قسمت های صدادر شبه پرلود می باشند نیز توسط این سیستم جدا شده است.

در واقع نتایج موجود در [۴۳] نشان می دهد که سیستم پیشنهادی در مقابل تداخل مقاوم می باشد و در شرایطی که انرژی سیگنال تداخلی زیاد باشد نیز قادر به تخمین خوبی از محدوده فرکانس گام و سیگنال گفتار صدادر است. همچنین نتایج ارزیابی نشان می دهد که عملکرد سیستم پیشنهادی در جداسازی گفتار در شرایط تک میکروفونه در مقایسه با روش CASA بیان شده، بهتر عمل می کند.

۲-۶- تخمین فرکانس گام

یکی از مسائل اولیه در آنالیز گفتار، تعیین فرکانس گام است. به عبارت دیگر، فرکانس گام یکی از ویژگی های کلیدی برای سیستم های جداسازی گفتار بر پایه گام است. الگوریتم تعیین ^۱PDA مستقیماً از مدل های ادراک گام الهام گرفته است. در این مدل ها فرض می شود که گام به عنوان تناوب

^۱Pitch Determination Algorithm

الگوهای عصبی در حوزه زمان قابل مشاهده است [۴۴] و یا این که درحوزه فرکانس اجزا هارمونیک توسط حلزونی گوش^۱ قابل تفکیک است.

مکانیسم‌های زمانی سرنخ‌هایی را برای ردیابی تناوب‌ها در حوزه زمان فراهم می‌کنند. از جمله این مکانیسم‌ها می‌توان به محل قطع صفر^۲ [۴۵]، فیلتر پایین‌گذر [۲۹]، تابع خودهمبستگی [۳۲]، توابع تفاضلی و ترکیبات آن‌ها اشاره نمود. از طرف دیگر، مکانیسم‌های طیفی برای درک گام، آنالیز مؤلفه‌های فرکانسی جداگانه را پیشنهاد می‌کنند که از آن‌ها برای تخمین بهترین جاسازی^۳ "الگوی گام"^۴ استفاده می‌شود. روش‌های مختلفی بر پایه تطبیق الگوها مانند: شانه طیفی^۵، الک طیفی^۶ و مجموع زیر هارمونیک‌ها پیشنهاد گردیده است. با ترکیب دو دسته روش بالا جهت درک گام، یک دسته روش به نام روش‌های زمان-طیفی ایجاد می‌شود که از تئوری Licklider [۴۶] منشأ گرفته شده و توسط دیگران گسترش یافته است.

در کاربردهای واقعی، یک ردیاب چند گام^۷، برای زمانی که صدای تداخلی شامل یک ساختار هارمونیک (مانند موزیک یا گفتار دیگر) باشد، مورد نیاز است. این عمل به دلیل همپوشانی هارمونیک منابع که باعث ضعیف شدن نشانه‌های گام منابع می‌شود، بسیار مشکل‌تر از تخمین یک گام است. تاکنون چندین روش برای ردیابی دو گام همزمان ارائه شده است. Toloen و Karjalainen یک تحلیل‌کننده چند گام را با به‌کارگیری دو باند وابسته به محدوده فرکانس بالا و پایین و نیز با استفاده از تابع خودهمبستگی مجموع بهبودیافته، طراحی کرده‌اند [۴۷]. Wu و دیگر همکارانش آماره‌های دوره تناوب گام را بر روی یک مکانیسم انتخاب کانال مدل کردند و از یک HMM برای استخراج منحنی‌های گام پیوسته استفاده نمودند. Jordan یک مدل بر اساس مدل آماری طیف سیگنال با استفاده از یک HMM برای رفتار گام ارائه کرده است [۴۸].

¹Cochleagram

²Zero-crossing

³Best-Fitting

⁴Pitch template

⁵Spectral Comb

⁶Harmonic Sieve

⁷Multipitch

در [۴۹] طیف توان سیگنال مخلوط، به صورت مدل‌های منابع پارامتری که با استفاده از قسمت‌های صدا دار گفتار آموزش داده شده‌اند، مدل شده است. Klapuri در واقع یک مدل تخمین و حذف پیشنهاد داده است که با توجه به یک الگوریتم تکراری، نقاط گام را درموزیک دارای چندین صدا و سیگنال گفتار ردیابی می‌کند. Hu و Wang در الگوریتمی برای تخمین گام و جداسازی گفتار به صورت همزمان و تکراری ارائه کردند [۴۰].

۲-۷- جمع‌بندی و نتیجه‌گیری

در دنیای واقعی ترکیب گفتار و دیگر صوت‌ها توسط یک یا چند میکروفون، برای انجام پردازش گردآوری می‌شود. در محیط‌هایی نظیر مهمانی‌ها، استفاده از روش‌هایی مانند آنالیز مولفه‌های مستقل (ICA) یا فیلترینگ فضایی که در آن‌ها آرایه‌ای از میکروفون‌ها برای جداسازی گفتار مورد نظر استفاده می‌شود، نتایج مناسبی ندارند. همچنین در برخی محیط‌ها استفاده از چندین میکروفون امکان‌پذیر نبوده و تنها انتخاب، حالت تک‌میکروفونه خواهد بود.

در این فصل روش‌های موجود برای جداسازی همزمان گفتار تشریح شد. معایب و مزایای روش‌ها گفته و مقایسه شدند. در واقع یکی از چالش‌های مهم در بهسازی گفتار، جداسازی سیگنال گفتار هدف از سیگنال تداخلی شبیه به گفتار است. همانطور که در این فصل به آن اشاره شد، دقت روش‌های CASA در جداسازی گفتار تک‌میکروفونه، وابسته به دقت تخمین فرکانس گام دو گوینده همزمان است. این بدین دلیل است که در این روش‌ها، یک ماسک مناسب در حوزه T-F برای جداسازی گفتار با توجه به فرکانس گام تخمین زده شده، تولید می‌شود.

فصل سوم

تئوری الگوریتم‌های مورد استفاده

۳-۱- روش‌های استخراج ویژگی

۳-۱-۱- روش‌های حوزه زمان

روش‌های پردازش سیگنال حوزه زمان تنها از داده‌های زمانی به‌منظور تحلیل و آنالیز بهره می‌گیرند و هیچ‌گونه تبدیل دیگری بر داده‌ها اعمال نمی‌شود. در این روش‌ها عمدتاً از ویژگی‌های آماری سیگنال زمانی استفاده می‌شود.

۳-۱-۲- روش‌های حوزه فرکانس

در هنگام مطالعه رفتار یک سیگنال در حوزه زمان، تنها اطلاعات محدودی از آن به‌دست می‌آید و بسیاری از مشخصات مهم آن پنهان می‌ماند. بدین منظور سیگنال از فضایی به فضای دیگر انتقال داده می‌شود تا بعضی از اطلاعات مفید آن در حوزه جدید آشکار گردد. ابزار انتقال از حوزه زمان به فرکانس، تبدیل فوریه پیوسته و گسسته است. تبدیل فوریه که به‌صورت زیر تعریف می‌گردد، تابع $x(t)$ در حوزه زمان را به یک تابع فرکانسی $X(\omega)$ تبدیل می‌نماید.

$$X(\omega) = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (۱-۳)$$

تبدیل فوریه گسسته به‌صورت زیر تعریف می‌گردد.

$$X(K) = \sum_{n=-\infty}^{\infty} x(n) e^{-\frac{2\pi j n K}{N}} \quad (۲-۳)$$

به‌منظور افزایش سرعت عملیاتی، تبدیل فوریه سریع معرفی گردید. در واقع می‌توان گفت که در حال حاضر مهم‌ترین ابزار در پردازش و تحلیل سیگنال‌ها، این روش می‌باشد. تبدیل فوریه معمولاً برای پنجره‌ای کوچک از سیگنال اعمال می‌گردد تا سیگنال پایا باشد.

پس از محاسبه تبدیل فوریه یک سیگنال گسسته، بردارهای مختلفی به‌دست می‌آیند که شامل اطلاعات دامنه و فاز تبدیل فوریه می‌باشند.

۳-۱-۳- روش‌های حوزه زمان - فرکانس

پس از بیان روش‌های استخراج ویژگی در دو حوزه زمان و فرکانس، به روش‌هایی می‌پردازیم که اطلاعات دو حوزه را با هم در نظر می‌گیرند. یک مشکل اساسی در همه‌ی روش‌های حوزه فرکانس این است که سیگنال مورد بررسی را ایستا در نظر گرفته و محتوای فرکانسی را نسبت به زمان، ثابت می‌گیرند. این در حالی است که در اکثر کاربردهای عملی، سیگنال‌های صوتی غیر ایستا و محتوای فرکانسی آن‌ها، تابع زمان می‌باشند. بنابراین روش‌های جدیدی برای برطرف کردن این کاستی ارائه شده است که مهم‌ترین آن‌ها تبدیل فوریه زمان کوتاه و تبدیل موجک می‌باشند. در تبدیل فوریه پیوسته و گسسته بخشی از سیگنال در نظر گرفته می‌شود و محتوای فرکانسی آن به همه‌ی سیگنال تعمیم داده می‌شود. در محاسبه طیف توان متوسط نیز پنجره‌ای با طول مشخص برای سیگنال در نظر گرفته می‌شود و طیف فرکانسی برای آن محاسبه می‌گردد. سپس این پنجره در طول سیگنال حرکت داده می‌شود و پس از محاسبه طیف برای همه پنجره‌ها، مقادیر به‌دست آمده میانگین‌گیری شده و مقدار متوسط آن‌ها به‌عنوان طیف فرکانسی سیگنال در نظر گرفته می‌شود. در این روش قطعه‌ای از سیگنال که اقتباس می‌گردد، همیشه دارای طول یکسانی است. بنابراین تکه‌ی زمانی به‌کار رفته برای تحلیل یک جزء با فرکانس بالا، دارای همان طول زمانی به‌کار رفته، برای نوع با فرکانس پایین می‌باشد. در هر دو حالت ذکر شده، اطلاعات زمانی سیگنال از بین می‌رود و تخصیص یافتگی مناسبی در حوزه زمان وجود ندارد. برای رفع این مشکل راه‌حل اولیه‌ای پیشنهاد شده است که در نهایت منجر به ابداع تبدیل موجک گشته است. ساده‌ترین کار ممکن این است که هر بار که پنجره با طول ثابت روی سیگنال باز شده و طیف فرکانسی آن محاسبه می‌گردد، زمانی متناسب با آن پنجره به طیف به‌دست آمده اختصاص داده شود. با این کار در حین تغییر موقعیت پنجره، می‌توانیم تغییرات طیف فرکانسی سیگنال را نیز برحسب زمان داشته باشیم، چنین تبدیلی تبدیل فوریه زمان کوتاه نامیده می‌شود.

۳-۱-۴- آنالیز پیش‌گویی خطی^۱ (LPC)

یکی از مشهورترین تکنیک‌های آنالیز و سنتز گفتار، پیش‌گویی خطی است که به دلیل توانایی آن در نمایش شکل موج بر حسب پارامترهای متغیر با زمان، در بسیاری از کاربردهای کدگذاری گفتار به کار می‌رود. تکنیک‌های پیش‌گویی خطی از نظر محاسباتی بسیار سریع هستند و در تخمین پارامترهای سیگنال گفتار همانند دوره‌ی اصلی تناوب و فورمنت‌ها، ابزار ضروری محسوب می‌شوند. ایده‌ی اصلی، مبتنی بر این نظریه است که می‌توان طیف سیگنال گفتار را با پاسخ فرکانسی یک فیلتر تمام قطب، تقریب زد و ضرایب این فیلتر را به عنوان بردار مشخصه‌ی آن مورد استفاده قرار داد. در آنالیز پیش‌گویی خطی، یک نمونه از سیگنال گفتار در یک زمان مشخص، با ترکیب خطی از تعدادی از نمونه‌های قبلی آن، تخمین زده می‌شود. اگر $S(n)$ نمونه‌ای در زمان n باشد، می‌توان آن را با P نمونه‌ی قبلی آن به صورت زیر تقریب زد:

$$S(n) \cong a_1 S(n-1) + a_2 S(n-2) + \dots + a_p S(n-p) \quad (3-3)$$

اگر ضرایب a_1 تا a_p در طول سیگنال گفتار ثابت فرض شوند، معادله‌ی (۳-۴) را می‌توان به صورت زیر نوشت:

$$S(z) = \sum_{i=1}^p a_i z^{-i} S(z) + GU(z) \quad (4-3)$$

$$V(z) = \frac{S(z)}{U(z)} = \frac{G}{1 - \sum_{i=1}^p a_i z^{-i}} = \frac{G}{1 - P(z)} \quad (5-3)$$

به طوری که $V(z)$ یک فیلتر تمام قطب است که درجه‌ی آن P می‌باشد و مدل تقریباً خوبی برای مجرای گفتار^۲ و محفظه‌ی دهان می‌باشد. هدف در آنالیز پیش‌گویی خطی، به دست آوردن ضرایب این فیلتر یعنی a_1 تا a_p است. هر قدر که مرتبه‌ی مدل (P) بیشتر باشد، شکل دقیق‌تری از طیف سیگنال گفتار به دست می‌آید و مشخصه‌های بیشتر و دقیق‌تری توسط ضرایب a_1 تا a_p نشان داده

¹ Linear Predictive Analysis


² Vocal Tract

می‌شوند؛ البته زمان و پیچیدگی محاسبات نیز به همان اندازه بیشتر خواهد شد. مقدار P را اغلب ۸ (دو فورمنت اول)، ۱۲ (سه فورمنت اول) و یا ۱۶ (چهار فورمنت اول) در نظر می‌گیرند. ضرایب پیش-گویی خطی برای هر قاب پنجره شده، محاسبه می‌شود و به‌عنوان ویژگی، مورد استفاده قرار می‌گیرد.

۳-۱-۵- آنالیز کپسترال

یکی از مشخصه‌هایی که از سیگنال گفتار استخراج می‌شود و در بسیاری از کاربردها مورد استفاده قرار می‌گیرد، ضرایب کپسترال می‌باشد. این ضرایب نه تنها اطلاعات فیلتر مجرای گفتار را در خود دارند، بلکه حاوی اطلاعات سیگنال تحریک نیز می‌باشند. بنابراین مشخصه‌های مناسبی را برای تشخیص گفتار در اختیار قرار می‌دهند.

آنالیز کپسترال^۱ به دو دسته‌ی کپستروم حقیقی^۲ و کپستروم مختلط^۳ تقسیم می‌شود. تفاوت کپستروم حقیقی و مختلط این است که آنالیز کپستروم مختلط، حاوی اطلاعات فاز سیگنال صحبت نیز هست؛ ولی از آن‌جا که اطلاعات فاز در شنوایی انسان اهمیت کمی دارد، معمولاً از آنالیز کپستروم حقیقی استفاده می‌شود. شکل (۳-۱) بیانگر چگونگی محاسبه‌ی ضرایب کپسترال است.



شکل (۳-۱) نحوه‌ی محاسبه‌ی ضرایب کپسترال [۵۰]

ضرایب کپسترال با استفاده از ضرایب پیش‌گویی خطی نیز می‌توانند محاسبه شوند. اگر ضرایب پیش‌گویی خطی، ضرایب فیلتر رابطه‌ی (۳-۵) و از مرتبه‌ی P باشند، ضرایب LPCC به صورت رابطه‌ی (۳-۶) محاسبه می‌شوند:

^۱ Cepstral

^۲ Real Cepstrum

^۳ Complex Cepstrum

$$C(n) = \begin{cases} a(n) + \sum_{k=1}^{n-1} \frac{n-k}{n} a_k C_{n-k} & 1 \leq n \leq p \\ \sum_{k=1}^p \frac{n-k}{n} a_k C_{n-k} & p < n \leq \infty \end{cases} \quad (6-3)$$

که در رابطه $a(n)$ ضرایب LPC و $C(n)$ ضرایب کپسترال می‌باشند.

۳-۱-۶- استفاده از مقیاس MEL در آنالیز کپسترال

یکی از راه‌های بهبود دقت تشخیص سیستم، هنگامی که از ضرایب کپسترال به‌عنوان بردارهای ویژگی استفاده می‌شود، استفاده از یک تبدیل غیرخطی است که حساسیت گوش را نسبت به حوزه‌های مختلف فرکانس مدل کند. مسئله‌ی قابل توجه این است که باندهای مختلف فرکانس از نظر اطلاعات شنوایی، دارای ارزش‌های مختلفی هستند. خاصیت مقیاس مل^۱ این است که به اطلاعات حوزه‌ی پایین فرکانس ارزش بیشتری می‌دهد.

مل واحد ارزیابی صدای درک شده یا فرکانس آهنگ^۲ است. مقیاس MEL با رابطه‌ی زیر چنین تعریف می‌شود:

$$F_{mel} = 1000 \log_2(1 + F_{KHz}) \quad (7-3)$$

ثابت شده است که درک یک فرکانس ویژه، توسط سیستم شنوایی، تحت تاثیر انرژی یک باند بحرانی از فرکانس‌های پیرامون آن قرار دارد. پهنای باند بحرانی برای فرکانس‌های کمتر از یک کیلوهرتز برابر با ۱۰۰ هرتز است و برای فرکانس‌های بیش از یک کیلوهرتز، به صورت لگاریتمی افزایش می‌یابد. بنابراین برای محاسبه‌ی ضرایب مل کپستروم می‌توان لگاریتم انرژی کل در باندهای بحرانی حول فرکانس‌های مل را به عنوان ورودی تبدیل فوریه گسسته معکوس به کار گرفت و با محاسبه‌ی این تبدیل ضرایب مل کپستروم را محاسبه نمود. ضرایب مل کپستروم به صورت معادله (۳-۸) تعریف می‌شود.

^۱ Mel

^۲ Tone

$$C_s(n, m) = \frac{1}{N'} \sum_{k=0}^{N'-1} \bar{Y}(k) \cos(k \frac{2\pi}{N'} n) \quad (۸-۳)$$

ضرایب مل کپستروم به اختصار MFCC نامیده می‌شوند.

۳-۲- آموزش دیکشنری

بیشتر سیستم‌های CASA وابسته به ویژگی‌های مبتنی بر فرکانس گام می‌باشند. فرکانس گام برای دو گوینده زن و مرد در قسمت‌های زیادی همپوشانی دارد. بنابراین دنبال کردن چندین گام در یک سیگنال صدادار، کار بسیار مشکلی می‌باشد. در حالتی که دو گوینده همجنس (زن-زن و یا مرد-مرد) باشد، به مراتب کار سخت‌تر خواهد شد. بنابراین به جای استفاده از گام باید به دنبال ویژگی بهتری بود تا بتوان مولفه‌های فرکانسی هر کدام از گوینده‌ها را با دقت بیشتری جداسازی نمود.

در این پایان‌نامه، یک روش جداسازی تک‌میکروفون مبتنی بر ویژگی‌های تَنگ ارائه خواهیم داد. روش پیشنهادی برای هر کدام از گوینده‌ها یک دیکشنری از ویژگی‌های مناسب آموزش می‌دهد. سپس با استفاده از دیکشنری‌های آموزش دیده، صدای هر کدام از دو گوینده همزمان، بازسازی می‌شود. همچنین باید متذکر شد که روش پیشنهادی در این پایان‌نامه تلفیقی از روش یادگیری آماری و روش مبتنی بر ویژگی به منظور جداسازی تک‌میکروفون می‌باشد.

دیکشنری از مجموعه‌ای از بردارهای پایه (اتم) تشکیل شده است. هر ستون ماتریس دیکشنری یک بردار پایه می‌باشد. ایده‌ی این روش بر این اساس استوار است که می‌توان یک بردار را به صورت ترکیب خطی از بردارهای دیگر بیان کرد. برای مثال اگر بردار P به صورت ترکیب خطی از اتم‌ها بیان شود و n تعداد اتم‌ها در دیکشنری باشد، خواهیم داشت:

$$P = \alpha_1 p_1 + \alpha_2 p_2 + \alpha_3 p_3 + \dots = \sum_{j=1}^n \alpha_j p_j \quad (۹-۳)$$

$$P = Dq \quad (۱۰-۳)$$

به طوری که p_i ها بردارهای پایه می‌باشند و $q = (\alpha_1 \ \alpha_2 \ \dots + \alpha_n)^T$ بردار ضرایب است که اهمیت هر اتم را برای ساخت بردار P ، تعیین می‌کند. $D = (p_1 \ p_2 \ \dots + p_n)$ دیکشنری مورد

استفاده برای به دست آوردن ارائه‌ی تنک بردار P می‌باشد. بردار بازسازی شده باید تا حد ممکن به بردار مورد نظر نزدیک باشد. بردار ضرایب q به وسیله‌ی حل معادله‌ی بهینه‌سازی زیر به دست می‌آید:

$$q = \operatorname{argmin}_q \|Dq - P\| + \gamma \|\alpha\|_0 \quad (11-3)$$

$$D = \operatorname{argmin}_D \|Dq - P\| + \gamma \|\alpha\|_0 \quad (12-3)$$

آموزش دیکشنری یک مرحله مهم در روش پیشنهادی می‌باشد. یک دیکشنری مناسب می‌تواند عملکرد سیستم را بالا ببرد و بالعکس. یکی از الگوریتم‌های ارائه شده برای آموزش دیکشنری، الگوریتم K-SVD می‌باشد. روش K-SVD از تجزیه‌ی مقادیر منفرد برای آموزش دیکشنری استفاده می‌نماید. این روش حالت توسعه یافته‌ای از الگوریتم K-means می‌باشد. این الگوریتم با مینیمم کردن معادله‌ی (11-3) نسبت به q ابتدا مقادیر کدگذاری تنک (q) برای دیکشنری اولیه را محاسبه می‌نماید، سپس با ثابت در نظر گرفتن کدگذاری تنک به دست آمده، با استفاده از معادله (12-3)، سعی می‌کند اتم‌های موجود در دیکشنری را برای تطبیق بهتر، به روزرسانی نماید. دیکشنری اولیه معمولاً از مقادیر تصادفی به دست می‌آید. این الگوریتم تکراری آنقدر ادامه پیدا می‌کند تا خطای بازسازی تمام نمونه‌های آموزشی با دیکشنری به دست آمده مینیمم شود [51].

۳-۲-۱- کدگذاری تنک یک سیگنال صوتی

کدگذاری تنک ارائه‌ی سیگنال مورد نظر با کمترین تعداد ممکن، از اتم‌های یک دیکشنری می‌باشد. در ارائه‌ی فرکانسی-زمانی سیگنال X (تبدیل فوریه زمان کوتاه)، هر ستون بیانگر ویژگی استخراج شده از یک پنجره‌ی زمان کوتاه از سیگنال ورودی است. مشاهده‌ی X_i (یک ستون از ماتریس تبدیل فوریه زمان کوتاه) می‌تواند با استفاده از دیکشنری D به صورت تنک رمزگذاری شود. بنابراین:

$$X_i = D\alpha \quad (13-3)$$

به طوری که D یک ماتریس $m \times p$ ($m > p$)، X_i یک ماتریس $m \times 1$ و α یک ماتریس $p \times 1$ می‌باشد. بنابراین در این مسئله، تخمین α را طوری می‌یابیم که شرط تنک بودن α همواره برقرار باشد. شرط

تُنک بودن باعث می‌شود که فقط تعداد کمی از عناصر موجود در α غیر صفر باشند و بقیه عناصر باید صفر باشند. به هر کدام از ستون‌های ماتریس D ، یک اتم گفته می‌شود. در مسئله‌ی کدگذاری تُنک، هر سیگنال X_i به صورت ترکیب خطی تعداد کمی از اتم‌های موجود در دیکشنری D نوشته می‌شود. بنابراین مسئله‌ی تخمین تُنک نمونه X_i به صورت زیر قابل بیان می‌باشد:

$$\min_{\alpha \in \mathbb{R}^{p \times 1}} \|\alpha\|_0 \quad \text{such that } X_i = D\alpha \quad (14-3)$$

نرم l_0 یک شبه نرم^۱ می‌باشد که عناصر غیر صفر α را می‌شمارد. حل این مسئله بسیار مشکل می‌باشد. الگوریتم‌های زیادی برای حل این مسئله پیشنهاد شده است. در این پایان‌نامه از OMP^2 برای حل این مسئله استفاده شده است [۵۲].

۳-۲-۲- الگوریتم OMP

هدف اصلی الگوریتم OMP به دست آوردن تخمینی از مسئله‌ی کدگذاری تُنک به وسیله‌ی قید تُنک بودن می‌باشد. مسئله‌ی کدگذاری تُنک به وسیله‌ی معادله‌ی زیر بیان می‌شود:

$$\alpha = \operatorname{argmin}_{\alpha} \|X_i - D\alpha\|_2^2 \quad \text{subject to } \|\alpha\|_0 < k \quad (15-3)$$

به طوری که k بیشترین تعداد اتم‌های شرکت کننده در فرایند بازسازی سیگنال X_i را دارا می‌باشد. در الگوریتم OMP اتمی که بیشترین همبستگی را با باقی‌مانده هر مرحله داشته باشد، به عنوان یکی از اتم‌های شرکت کننده در بازسازی سیگنال در نظر گرفته می‌شود. بعد از چندین تکرار، این الگوریتم سیگنال ورودی را بر حسب ترکیب خطی اتم‌های موجود در دیکشنری D ، بیان می‌کند. الگوریتم OMP در زیر بیان شده است [۵۲].

در این الگوریتم، متغیر I اندیس اتم‌های انتخاب شده در هر مرحله را نگهداری می‌کند، r مقدار باقی‌مانده در هر مرحله است و α خروجی ارائه تُنک می‌باشد. در این الگوریتم ابتدا اتمی که بیشترین همبستگی را با باقی‌مانده هر مرحله داشته باشد، انتخاب می‌شود (مرحله ۵). سپس شماره‌ی اتم

¹ pseudo-norm

² Orthogonal matching pursuit

انتخاب شده در مرحله قبل، به متغیر I اضافه می‌شود (مرحله ی ۶). در مرحله ی ۷ اتم‌های انتخاب شده به فضای سیگنال X_i برده می‌شوند و در مرحله ی ۸ مقدار باقی‌مانده به‌روز می‌شود [۵۳].

الگوریتم OMP

- ۱- ورودی: دیکشنری D ، سیگنال ورودی X_i و معیار تُنک بودن k
 - ۲- خروجی: ارائه ی تُنک α به‌صورتی که $X_i = D\alpha$
 - ۳- مقداردهی اولیه: $\alpha = 0$ ، $r = X_i$ ، $I = []$
 - ۴- تا زمانی که شرط تُنک بودن $\|\alpha\|_0 < k$ محقق نشده است مراحل زیر انجام شود:
 - ۵- $\hat{u} = \operatorname{argmax}_k |d_k^T r|$
 - ۶- $I = [I; \hat{u}]$
 - ۷- $\alpha_I = (D_I)^+ X_i$
 - ۸- $r = X_i - D_I \alpha_I$
 - ۹- پایان
-

۳-۲- جمع‌بندی و نتیجه‌گیری

در این فصل به تشریح استخراج ویژگی‌های مورد نظر برای یک سیگنال صوتی پرداختیم. در واقع یک سیگنال صوتی دارای ویژگی‌های گسترده‌ای است که نمی‌توان همه‌ی آن‌ها را استخراج کرد. به-همین منظور روی سیگنال صوتی تبدیلاتی انجام می‌دهیم تا بتوانیم از این طریق روی قسمت‌هایی از اطلاعات تمرکز کرده و آن‌ها را به‌عنوان ویژگی سیگنال به‌منظور مقایسه‌ی سیگنال‌ها با یکدیگر استخراج کنیم. همچنین بعد از تشریح استخراج ویژگی‌ها، به آموزش دیکشنری و زیرمجموعه‌های مربوط به آن برای استفاده در روش پیشنهادی خود پرداختیم.

فصل چهارم

روش پیشنهادی و پیاده سازی آن

۴-۱- مقدمه

در این فصل روش پیشنهادی برای جداسازی صدای دو گوینده‌ی همزمان از یک صدای مخلوط بیان می‌شود. یکی از چالش‌های موجود در این حوزه جداسازی صدای گوینده‌های هم‌جنس می‌باشد. با توجه به این که اکثر روش‌های موجود از تخمین گام برای جداسازی صدا استفاده می‌نمایند و فرکانس گام گوینده‌های هم‌جنس بسیار به هم نزدیک می‌باشد، بنابراین در جداسازی صدای هم‌جنس روش‌های موجود با مشکل روبرو می‌باشند. همانطور که در بخش نتایج خواهید دید روش پیشنهادی قادر است که صدای گوینده‌های هم‌جنس را نیز به خوبی گوینده‌های غیر هم‌جنس جدا کند.

برخلاف روش‌هایی مانند [۳۷]، که در آن‌ها عملیات جداسازی از طریق ردیابی گام گوینده‌های مختلف انجام می‌شود، در روش پیشنهادی عملیات جداسازی از طریق مدل‌سازی صدای گوینده‌های مختلف صورت می‌گیرد. در حقیقت نوآوری روش پیشنهادی مدل‌سازی صدای گوینده‌های مختلف با استفاده از آموزش دیکشنری می‌باشد. در روش پیشنهادی هر بردار ویژگی استخراج شده از صدای مخلوط بر حسب بردارهای پایه‌ی گوینده‌های مختلف تجزیه می‌شود. و در نهایت صدای جداسازی شده از طریق ترکیب بردارهای پایه‌ی یک گوینده مشخص به دست می‌آید.

در روش پیشنهادی، برخلاف روش‌های پیشین مانند [۳۷] و [۴۰]، فرکانس جداسازی، محدود نمی‌باشد. همچنین یکی از محاسن روش پیشنهادی محدود نبودن به دو گوینده می‌باشد، یعنی می‌توان با تعمیم روش پیشنهادی صدای مخلوط تعداد بیشتری گوینده را نیز جداسازی کرد. در روش پیشنهادی از ویژگی و خواص تبدیل فوریه زمان کوتاه برای جداسازی سیگنال صوتی استفاده شده است، درحالی که اکثر روش‌هایی که تاکنون پیشنهاد شده است از کالکیگرام و یا فیلتربانک گاماتون برای جداسازی استفاده کرده‌اند. سادگی ویژگی مورد استفاده در روش پیشنهادی باعث کاهش زمان لازم برای جداسازی می‌شود. روش پیشنهادی یک روش با نظارت می‌باشد. در روش پیشنهادی ابتدا نمونه‌های صدای دو گوینده همزمان مدل‌سازی می‌شود. این مدل‌سازی به وسیله‌ی آموزش یک دیکشنری و به دست آوردن بردارهای پایه‌ی مربوط به هر کدام از گوینده‌ها انجام می‌شود. بعد از

مرحله‌ی مدل‌سازی، برای هر صدا مولفه‌های فرکانسی مربوط به هر کدام از دو گوینده همزمان جداسازی می‌شود. به‌منظور کاهش نویز صدای خروجی و حذف مولفه‌های فرکانسی سیگنال‌های تداخل، یک مرحله‌ی پس‌پردازش^۱ نیز روی صدای خروجی انجام می‌شود. نتایج خروجی نشان می‌دهد که روش پیشنهادی طبق معیار SNR (نسبت سیگنال به نویز) و MSE (خطای میانگین مربعات)، که در فصل بعد به آن‌ها اشاره می‌شود برتری قابل توجهی نسبت به سایر روش‌های موجود دارد. روش پیشنهادی شامل سه بخش آموزش، تست و پس‌پردازش می‌باشد. در بخش بعد هر کدام از این مراحل در الگوریتم‌های پیشنهادی ۱، ۲ و ۳ توضیح داده شده‌اند.

۴-۲- الگوریتم‌های پیشنهادی

الگوریتم پیشنهادی ۱: فاز آموزش

- ۱- برای هر کدام از گویندگان مراحل ۲ تا ۶ اجرا شود.
- ۲- برای تمام صداهای آموزشی مراحل ۳ و ۴ اجرا شود.
- ۳- بخش‌بندی صدای ورودی
- ۴- استخراج ویژگی تبدیل فوریه، MFCC و LPC از فریم‌های موجود در صدای ورودی.
- ۵- تشکیل ماتریس ویژگی گوینده.
- ۶- استفاده از الگوریتم K-SVD برای به‌دست آوردن بردارهای پایه و مدل‌سازی صدای گوینده.

الگوریتم پیشنهادی ۲: فاز تست

- ۱- کنار هم قرار دادن دیکشنری‌های تمام گویندگان و تشکیل دیکشنری جامع.
- ۲- برای هر صدای تست مراحل ۳ تا ۱۰ اجرا شود.
- ۳- بخش‌بندی صدای ورودی.
- ۴- استخراج ویژگی تبدیل فوریه از هر فریم صدای ورودی.
- ۵- به‌ازای هر فریم موجود در صدای ورودی مراحل ۶ تا ۸ اجرا شود.
- ۶- پیدا کردن ضرایب اسپارس مربوط به ویژگی استخراج شده از این فریم.
- ۷- جداسازی ضرایب مربوط به هر کدام از گویندگان.
- ۸- به‌دست آوردن بردار ضرایب تبدیل فوریه صدای جداسازی شده در این فریم.

¹ Postprocessing

۹- به دست آوردن ماتریس تبدیل فوریه زمان کوتاه هر گوینده.

۱۰- محاسبه‌ی عکس تبدیل فوریه و بدست آوردن صدای جداسازی شده.

الگوریتم پیشنهادی ۳: فاز پس پردازش

۱- برای هر صدای جداسازی شده مراحل ۲ تا ۷ اجرا شود.

۲- بخش‌بندی صدا.

۳- استخراج ویژگی MFCC و LPC از هر فریم.

۴- تشکیل بردار ویژگی $F = \begin{bmatrix} MFCC \\ LPC \end{bmatrix}$.

۵- پیدا کردن نزدیک‌ترین بردار به بردار F در ماتریس ویژگی C .

۶- جایگزین کردن بردار حوزه‌ی زمان مربوط به این ویژگی.

۷- میانگین‌گیری در مناطقی که همپوشانی دارد.

در ادامه هر کدام از مراحل بالا با جزئیات بیشتر شرح داده می‌شوند:

۴-۳- فاز آموزش

۴-۳-۱- بخش‌بندی

سیگنال صوتی یک سیگنال غیر ایستا می‌باشد. برای توصیف بهتر سیگنال‌های غیر ایستا از بخش‌بندی استفاده می‌شود. بخش‌بندی به عملیات تبدیل سیگنال اصلی به تکه‌های کوتاه زمان گفته می‌شود. در این پایان‌نامه هر سیگنال صوتی به فریم‌های کوتاه زمان ۲۵ میلی ثانیه‌ای تقسیم می‌شود. به‌منظور استخراج جزئیات کامل سیگنال، فریم‌های کوتاه زمان با همپوشانی انتخاب می‌شوند. بدیهی است هر چه همپوشانی بین فریم‌ها بیشتر باشد اطلاعات استخراج شده کامل‌تر می‌باشد. اما باید در نظر داشت که همپوشانی زیاد بین فریم‌های استخراج شده باعث افزایش پیچیدگی محاسباتی الگوریتم می‌شود. بنابراین در این پایان‌نامه از همپوشانی ۵۰ درصد بین فریم‌ها برای استخراج اطلاعات استفاده می‌شود.

۴-۳-۲- استخراج ویژگی

در مرحله قبل هر سیگنال صوتی به تعدادی فریم با تعداد نمونه‌های برابر تقسیم شد. اگر هر کدام از فریم‌های استخراج شده را به صورت برداری بنویسیم، داریم:


$$P_i = \text{vec}(S_i) \quad (۱-۴)$$

به طوری که S_i فریم i -ام از سیگنال S می‌باشد. عملگر vec ، عملگر تبدیل یک فریم سیگنال صوتی به بردار ستونی می‌باشد.

در این مرحله لازم است اطلاعات موجود در تمام سیگنال‌های صوتی مربوط به یک گوینده‌ی مشخص در یک ماتریس جمع‌آوری شود. اگر تمام P_i های یک گوینده مشخص کنار یکدیگر قرار داده شوند ماتریس P به صورت زیر به وجود می‌آید:

$$P = [P_0, P_1, P_2, \dots, P_i, \dots, P_n] \quad (۲-۴)$$

در شکل (۱-۴) نحوه تشکیل ماتریس P نشان داده شده است.



شکل (۱-۴) نحوه‌ی تشکیل ماتریس P

در این مرحله از هر کدام از ستون‌های ماتریس P سه ویژگی استخراج می‌شود. (۱) تبدیل فوریه،

(۲) MFCC، (۳) LPC.

از ویژگی تبدیل فوریه در قسمت آموزش و تست استفاده خواهد شد و از ویژگی MFCC و LPC

برای بهبود عملکرد الگوریتم پیشنهادی استفاده می‌شود.

➤ تبدیل فوریه

تبدیل فوریه مهم‌ترین ویژگی مورد استفاده در این پایان‌نامه می‌باشد. تبدیل فوریه دارای خواص منحصر به فردی می‌باشد که آن را از سایر ویژگی‌های مرسوم سیگنال‌های صوتی متمایز کرده است. ویژگی خطی بودن و معکوس پذیر بودن تبدیل فوریه کارایی منحصر به فردی به آن برای جداسازی سیگنال صوتی می‌دهد. اگر دو سیگنال به نام‌های s_1 و s_2 داشته باشیم تبدیل فوریه آن‌ها به صورت زیر می‌باشد:

$$S_1 = F(s_1) \quad (3-4)$$

$$S_2 = F(s_2) \quad (4-4)$$

به صورتی که S_1 و S_2 به ترتیب تبدیل فوریه سیگنال s_1 و s_2 می‌باشند.

حال اگر سیگنال s_3 را به صورت زیر تعریف نماییم:

$$s_3 = s_1 + s_2 \quad (5-4)$$

تبدیل فوریه سیگنال s_3 به صورت زیر به دست می‌آید:

$$S_3 = F(s_3) = F(s_1 + s_2) \quad (6-4)$$

با توجه به خاصیت خطی بودن تبدیل فوریه خواهیم داشت:

$$F(s_1 + s_2) = F(s_1) + F(s_2) \quad (7-4)$$

بنابراین:

$$S_3 = S_1 + S_2 \quad (8-4)$$

بدین معنی که اگر سیگنال s_3 ترکیب خطی سیگنال s_1 و s_2 باشد، تبدیل فوریه S_3 نیز ترکیب خطی تبدیل فوریه‌ی این دو سیگنال می‌باشد. این خاصیت تبدیل فوریه را به ویژگی منحصر به فردی برای جداسازی سیگنال صوتی تبدیل می‌نماید. با توجه به مقدمه بالا اگر صدای دو گوینده در حوزه‌ی زمان با هم مخلوط شده باشند، می‌توانیم عملیات جداسازی را در حوزه‌ی فرکانس انجام دهیم.

خاصیت مهم دیگر تبدیل فوریه قابلیت معکوس پذیری آن می باشد. بعد از جداسازی مولفه های فرکانسی سیگنال می توان از قابلیت معکوس پذیری تبدیل فوریه استفاده نمود و سیگنال حوزه زمان آن را به دست آورد.


با توجه به مطالب گفته شده، در این پایان نامه از خواص تبدیل فوریه زمان کوتاه برای جداسازی صدای گوینده ها استفاده می شود. اگر p_i یک ستون از ماتریس P باشد، ضرایب تبدیل فوریه f_i به صورت زیر به دست می آید:

$$f_i = \text{abs}(F(p_i)) \quad (9-4)$$

به صورتی که F عملگر استخراج ضرایب تبدیل فوریه از سیگنال P_i می باشد. عملگر $\text{abs}(\cdot)$ مقدار قدر مطلق یک بردار را برمی گرداند. f_i اندازه ی ضرایب تبدیل فوریه ی سیگنال P_i می باشد. اگر از تمام فریم های موجود در ستون های ماتریس P تبدیل فوریه گرفته شود ماتریس حاصل به صورت زیر خواهد بود:

$$F = [f_0, f_1, f_2, \dots, f_i, f_n] \quad (10-4)$$

در شکل (۲-۴) ماتریس اندازه ی تبدیل فوریه زمان کوتاه مربوط به یک گوینده خاص نشان داده شده است.



شکل (۲-۴) ماتریس اندازه ی تبدیل فوریه زمان کوتاه مربوط به یک گوینده خاص

➤ ویژگی MFCC و LPC

بعد از این که صدای گوینده های مختلف توسط عکس تبدیل فوریه جداسازی شد، ممکن است تعدادی از مولفه های فرکانسی به اشتباه به یکی از گوینده ها نسبت داده شوند، در صورتی که

متعلق به گوینده دیگر باشند. بنابراین برای بهبود عملکرد الگوریتم و همچنین افزایش دقت جداسازی نیاز به یک مرحله پس پردازش می باشد. با توجه به عملکرد مناسبی که ویژگی های MFCC و LPC در شناسایی صداهای مختلف از خود نشان داده اند، در این پایان نامه ویژگی های MFCC و LPC را از هر بردار موجود در ماتریس P به صورت زیر استخراج می نماییم:

$$m_i = MFCC(p_i) \quad (۱۱-۴)$$


$$l_i = LPC(p_i) \quad (۱۲-۴)$$

به صورتی که p_i بردار i -ام موجود در ماتریس P می باشند. MFCC و LPC به ترتیب عملگرهای استخراج ویژگی MFCC و LPC می باشند. m_i و l_i به ترتیب ویژگی های MFCC و LPC استخراج شده از بردار p_i می باشند.

اگر از تمام بردارهای موجود در ماتریس P به صورت بالا ویژگی MFCC و LPC استخراج شود، می توان ماتریس ویژگی به منظور عملیات پس پردازش را به صورت زیر تعریف کرد:

$$C = \begin{bmatrix} m_0 & m_1 & \dots & m_n \\ l_0 & l_1 & \dots & l_n \end{bmatrix} \quad (۱۳-۴)$$

در شکل (۳-۴) نحوه ی تشکیل ماتریس ویژگی به منظور عملیات پس پردازش نشان داده شده است.




شکل (۳-۴) نحوه ی تشکیل ماتریس ویژگی به منظور عملیات پس پردازش

۴-۳-۳- آموزش دیکشنری

مرحله بعد، ساخت یک دیکشنری برای هر کدام از گوینده‌ها با استفاده از ماتریس F استخراج شده در مرحله قبل می‌باشد. همانطور که در فصل قبل توضیح داده شد، الگوریتم K-SVD دیکشنری مورد نیاز برای ارائه‌ی هر بردار دلخواه بر حسب ترکیب خطی بردارهای پایه را می‌سازد. دیکشنری آموزش-یافته قادر است هر بردار دلخواه را بر حسب ترکیب خطی تعداد اندکی از اتم‌های موجود در دیکشنری بیان کند. دیکشنری مورد استفاده در الگوریتم پیشنهادی شامل ۱۰۰۰ اتم برای هر گوینده می‌باشد. طول بردار هر اتم ۵۱۳ می‌باشد. بنابراین بعد از مرحله‌ی آموزش برای هر گوینده یک دیکشنری با ابعاد ۵۱۳×۱۰۰۰ خواهیم داشت.

تا این مرحله برای هر گوینده سه ماتریس (P و D و C) ساخته شده است که در مراحل بعدی الگوریتم، از آن‌ها استفاده خواهد شد. شکل (۴-۴) تمام ماتریس‌هایی که در مرحله‌ی آموزش ساخته شده‌اند را نشان می‌دهد.



شکل (۴-۴) تمام ماتریس‌های ساخته شده در مرحله‌ی آموزش برای دو گوینده

D_2 و D_1 به ترتیب دیکشنری‌های مربوط به گوینده‌ی اول و دوم می‌باشند که از طریق نتیجه‌ی الگوریتم K-SVD به دست آمده‌اند.

۴-۴- فاز تست

در فاز تست یک سیگنال مخلوط از صدای دو گوینده همزمان به الگوریتم داده خواهد شد و با توجه به مدل سازی که در مرحله قبل انجام شده است، الگوریتم سعی در جداسازی صدای دو گوینده دارد.

۴-۴-۱- بخش بندی سیگنال تست و استخراج ویژگی

این مرحله مشابه مرحله ی بخش بندی انجام شده در مرحله ی آموزش می باشد. سیگنال ورودی را به بخش هایی به طول ۲۵ میلی ثانیه با همپوشانی ۵۰ درصد تقسیم می کنیم. سپس از هر فریم استخراج شده از سیگنال تست، اندازه ی تبدیل فوریه گرفته می شود. تبدیل فوریه مورد استفاده در این پایان نامه شامل ۵۱۳ ضریب می باشد.

۴-۴-۲- تشکیل دیکشنری جامع

فلسفه ی ساخت دیکشنری، ارائه ی یک سیگنال بر حسب ترکیب خطی بردارهای پایه ی موجود در دیکشنری می باشد. با توجه به این که هر کدام از دیکشنری های ساخته شده، قادر می باشند صدای یکی از گویندگان را بر حسب ترکیب خطی بردارهای پایه بیان کنند، بنابراین یک دیکشنری جامع که شامل بردارهای پایه ی هر دو دیکشنری باشد، قادر است سیگنال صوتی مخلوط را بر حسب اتم های موجود در این دیکشنری ارائه دهد. برای تشکیل دیکشنری جامع به صورت زیر عمل می نمائیم:

$$D = [D_1, D_2] \quad (۴-۱۴)$$

به صورتی که D_1 و D_2 دیکشنری مربوط به گوینده ی اول و دوم می باشند و D دیکشنری جامع است.

۴-۴-۳- محاسبه ی ضرایب تُنک

بعد از این که از هر فریم صدای تست ویژگی تبدیل فوریه استخراج شد، لازم است ضرایب اسپارس این ویژگی برای عملیات جداسازی محاسبه شود. در حقیقت با محاسبه ی ضرایب اسپارس یک بردار

ویژگی، سهم هر دیکشنری از مولفه‌های بردار ویژگی مشخص می‌شود. اگر f_i بردار اندازه‌ی تبدیل فوریه زمان کوتاه مربوط به فریم i -ام صدای تست باشد، داریم:

$$\alpha = \operatorname{argmin}_{\alpha} \|f_i - D\alpha\| + \gamma \|\alpha\|_0 \quad (۱۵-۴)$$

با حل این معادله، ضرایب α به گونه‌ای به دست می‌آید که بردار f_i توسط دیکشنری D توصیف شود. همانطور که در معادله‌ی بالا مشخص است، $\|\alpha\|_0$ شرط تنگ بودن را به معادله اضافه می‌نماید. این معادله توسط الگوریتم OMP قابل حل خواهد بود.

۴-۴-۴ جداسازی مولفه‌های فرکانسی

بعد از این که ضرایب α به دست آمد، می‌توان سهم هر دیکشنری از این ضرایب را جداسازی کرد؛ بدین معنی که بردار ضرایب α به دو قسمت ۱۰۰۰ تایی تقسیم می‌شود، به گونه‌ای که ۱۰۰۰ ضریب اول سهم دیکشنری اول و ۱۰۰۰ ضریب دوم سهم دیکشنری دوم می‌باشد.

$$\alpha = \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \dots \\ \alpha_{1000} \\ \alpha_{1001} \\ \dots \\ \alpha_{2000} \end{bmatrix} = \begin{bmatrix} \hat{\alpha}_1 \\ \hat{\alpha}_2 \end{bmatrix} \quad (۱۶-۴)$$

$\hat{\alpha}_1$ ضرایب اسپارس دیکشنری D_1 و $\hat{\alpha}_2$ ضرایب اسپارس دیکشنری D_2 می‌باشد. عملیات جداسازی مولفه‌های فرکانسی توسط ضرب ضرایب اسپارس هر دیکشنری در همان دیکشنری انجام می‌شود.

$$h_1 = D_1 \hat{\alpha}_1 \quad (۱۷-۴)$$

$$h_2 = D_2 \hat{\alpha}_2 \quad (۱۸-۴)$$

h_1 مولفه‌ی فرکانسی مربوط به گوینده‌ی اول و h_2 مولفه‌ی فرکانسی مربوط به گوینده دوم می‌باشد. مراحل بالا برای تمام فریم‌های صدای مخلوط انجام می‌شود تا مولفه‌های فرکانسی تمام فریم‌ها جداسازی شود.

۴-۴-۵- تبدیل فوریه معکوس

اگر عملیات جداسازی را برای تمام فریم‌های موجود در صدای مخلوط انجام دهیم، در نهایت دو ماتریس شامل مولفه‌های فرکانسی گوینده‌ی اول و دوم خواهیم داشت. حال اگر از هر کدام از ماتریس‌های به‌دست آمده عکس تبدیل فوریه زمان کوتاه بگیریم، صدای جداسازی شده مربوط به هر کدام از گوینده‌ها به‌دست می‌آید. با توجه به این که گوش انسان به فاز موجود در صدا حساس نمی‌باشد، برای انجام عملیات معکوس تبدیل فوریه از فاز صدای مخلوط استفاده می‌نمائیم.

۴-۵- پس‌پردازش

بعد از این که صدای هر کدام از دو گوینده همزمان توسط روش پیشنهادی جداسازی شد، برای افزایش دقت جداسازی و همچنین کاهش نویز، از یک مرحله پس‌پردازش روی صداها جداسازی شده استفاده می‌شود. در پس‌پردازش پیشنهادی، هر فریم از صدای جداسازی شده، با نزدیک‌ترین فریم از فریم‌های آموزشی (از لحاظ فاصله‌ی اقلیدسی بردارهای هر دو فریم) جایگزین می‌شود. بعد از این عملیات می‌توان اطمینان حاصل کرد که تمام مولفه‌های فرکانسی صدای جداسازی شده به‌درستی شناخته شده است.

با توجه به عملکرد بسیار خوبی که ویژگی MFCC و LPC در شناسایی صدای گویندگان از خود نشان داده‌اند، در این پایان‌نامه از این دو ویژگی برای یافتن نزدیک‌ترین فریم به خروجی استفاده می‌نمائیم. مراحل اجرای پس‌پردازش به شرح زیر است:

۴-۵-۱- بخش‌بندی صدای جداسازی شده و استخراج ویژگی

همانند بخش‌بندی انجام شده در مرحله‌ی آموزش، در این مرحله نیز صدای خروجی مرحله‌ی تست را بخش‌بندی می‌نمائیم. هر دو صدای خروجی مرحله‌ی تست را به فریم‌های ۲۵ میلی ثانیه‌ای با همپوشانی ۵۰ درصد تقسیم می‌نمائیم. در مرحله‌ی بعد، از هر فریم صدا، ویژگی‌های MFCC و LPC را همانند آنچه در بخش قبل گفته شد استخراج می‌نمائیم. اگر $\bar{m}$ بردار ویژگی MFCC

استخراج شده از این فریم و $\bar{L}$ بردار ویژگی LPC استخراج شده از این فریم باشد، در مرحله‌ی بعد به دنبال نزدیک‌ترین فریم در فریم‌های آموزشی با توجه به این ویژگی می‌باشیم.

۴-۵-۲- انتخاب بهترین فریم

نزدیک‌ترین فریم به نحوی انتخاب می‌شود که بردار ویژگی فریم مورد نظر، به بردار ویژگی فریمی که قصد پس‌پردازش آن را داریم، به لحاظ فاصله‌ی اقلیدسی نزدیک باشد، یعنی:

$$C_j = \operatorname{argmin}_j \left\| C_j - \left[\frac{\bar{m}}{\bar{L}} \right] \right\|_2^2 \quad (۱۹-۴)$$

از آن جایی که تعداد بردارهای ماتریس C و ماتریس P یکسان هستند و بردارهای موجود در این دو ماتریس متناظر می‌باشند، بنابراین بعد از پیدا کردن نزدیک‌ترین فریم درون ماتریس C می‌توان بردار متناظر با آن را در ماتریس P جایگزین کرد. در حقیقت، با این روش نویزها و مولفه‌های فرکانسی که به صدا اضافه شده‌اند حذف خواهد شد.

۴-۶- جمع‌بندی و نتیجه‌گیری

در این فصل روش پیشنهادی در سه مرحله‌ی آموزش، تست و پس‌پردازش به‌صورت کامل بیان شد. ابتدا، نمونه صداهای دو گوینده همزمان را از طریق آموزش یک دیکشنری مدل‌سازی کردیم. سپس در مرحله‌ی تست، جداسازی دو گوینده همزمان بر اساس ویژگی تَنک (ضرایب اسپارس) ارائه شد. همچنین، به‌منظور کاهش نویز صدای خروجی و حذف مؤلفه‌های فرکانسی سیگنال‌های تداخل، یک مرحله پس‌پردازش روی صدای خروجی انجام شد.

فصل پنجم

نتایج تجربی شیشه سازی

۵-۱- مقدمه

در فاز آموزش روش ارائه شده، هر سیگنال صوتی به فریم‌های ۲۵ میلی ثانیه‌ای با همپوشانی ۵۰ درصد تقسیم می‌شود. سیگنال صوتی ورودی با نرخ بیت ۲۵ کیلو نمونه بر ثانیه ضبط شده است. در هر ۲۵ میلی ثانیه، ۶۲۵ نمونه موجود می‌باشد. بنابراین بردار $p_i \in R^{625 \times 1}$ می‌باشد. برای استخراج ویژگی تبدیل فوریه، از ۱۰۲۴ ضریب استفاده شده است که با حذف ضرایب فوریه فرکانس‌های منفی، برداری به طول ۵۱۳ ضریب متناظر با هر بردار p_i وجود خواهد داشت. در استخراج ویژگی MFCC از ۱۳ ضریب و در استخراج ویژگی LPC از ۱۶ ضریب استفاده شده است. بنابراین بردار $C_i \in R^{29 \times 1}$ می‌باشد. دیکشنری گوینده به گونه‌ای آموزش داده می‌شود که هر اتم آن، بر حسب حداکثر ۲۵ اتم قابل ارائه می‌باشد. به منظور سرعت بخشیدن به فرآیند آموزش و تست، دیکشنری ساخته شده در روش ارائه شده دارای ۱۰۰۰ اتم می‌باشد. از آن جا که طول هر اتم ۵۱۳ می‌باشد، بنابراین $D \in R^{513 \times 1000}$ خواهد بود. در فاز تست هر دو دیکشنری مربوط به دو گوینده همزمان صدای مخلوط را به هم متصل می‌کنیم. دیکشنری جامع دارای ۲۰۰۰ اتم می‌باشد. الگوریتم OMP را به گونه‌ای اجرا می‌کنیم که هر بردار ویژگی استخراج شده از صدای تست را با حداکثر ۵۰ اتم بیان نماید. چون دیکشنری جامع ۲۰۰۰ اتم دارد، بنابراین بردار ارائه‌ی تنک نیز دارای ۲۰۰۰ عنصر می‌باشد که ۱۰۰۰ عنصر اول مربوط به دیکشنری D_1 و ۱۰۰۰ عنصر دوم آن مربوط به دیکشنری D_2 می‌باشد.

۵-۲- پایگاه داده آموزشی

الگوریتم ارائه شده یک الگوریتم با نظارت می‌باشد؛ بنابراین نیاز به یک پایگاه داده با تعداد زیادی صدای ضبط شده وجود دارد. از طرفی، چالش اصلی موجود در جداسازی صدای تک‌میکروفون، مربوط به جداسازی صدای هم‌جنس می‌باشد. بنابراین، لازم است پایگاه داده‌ی انتخاب شده هم شامل صدای مرد و هم زن باشد. پایگاه داده‌ی (SSC)^۱ [۵۴] شامل ۱۷۰۰۰ صدای ضبط شده‌ی گوینده مرد و زن

¹ Speech separation challenge

می‌باشد. در این پایگاه داده، ۳۴ گوینده موجود می‌باشد که حدوداً نیمی از آن‌ها مرد و نیمی دیگر زن می‌باشند. برای هر کدام از این ۳۴ گوینده ۵۰۰ صدای ضبط شده موجود است. هر فایل صوتی در این پایگاه داده شامل ۶ کلمه می‌باشد که کلمات بیان شده در نام فایل صوتی نوشته شده است. برای مثال فایل صوتی "bbaf2n" شامل جمله‌ی "bin blue at F 2 now" می‌باشد. جدول (۵-۱)، لیست تمام انتخاب‌های ممکن کلمات در این پایگاه داده را نشان می‌دهد. جملات موجود برای هر کدام از گوینده‌ها ترکیبی از تمام حالات ممکن در این جدول می‌باشد.

جدول (۵-۱) لیست انتخاب‌های ممکن در پایگاه داده‌ی مورد نظر

Command	Color	Preposition	Letter	Number	Adverb
bin(b)	blue (b)	at (a)	A-Z	0-9	again(a)
Lay(l)	green(g)	by(b)			now(n)
Place(p)	red (r)	in(i)			please(p)
Set(s)	white(w)	with(w)			soon(s)

در این پایان‌نامه، برای آموزش الگوریتم پیشنهادی از ۴ گوینده موجود در این پایگاه داده استفاده شده است. از بین این چهار گوینده، دو گوینده مرد و دو گوینده زن می‌باشند. گفتنی است صداهایی که برای تست استفاده شده‌اند، در فرآیند آموزش به الگوریتم داده نشده‌اند. همچنین صداهای انتخابی برای تست، به‌صورت کاملاً تصادفی انتخاب شده است.

۵-۳- معیار ارزیابی

برای مقایسه روش پیشنهادی با سایر روش‌ها از معیار SNR و MSE استفاده شده است. معیار SNR به‌صورت زیر محاسبه می‌شود:

$$SNR = 10 \log_{10} \left(\sum_t x_a^2[t] / \sum_t (x_a[t] - \hat{x}_a[t])^2 \right) \quad (۵-۱)$$

به‌صورتی که $x_a[t]$ و $\hat{x}_a[t]$ به‌ترتیب سیگنال تمیز و سیگنال تخمین زده شده خروجی می‌باشند.

همچنین، معیار MSE به‌صورت زیر محاسبه می‌شود:


$$MSE = \frac{1}{T} \sum_t (x_a[t] - \hat{x}_a[t])^2 \quad (2-5)$$

به صورتی که $x_a[t]$ و $\hat{x}_a[t]$ به ترتیب سیگنال تمیز و سیگنال تخمین زده شده خروجی می باشند و T تعداد کل نمونه های موجود در سیگنال $x_a[t]$ می باشد.

۵-۴- نتایج شبیه سازی

سه حالت مختلف برای آزمایش الگوریتم پیشنهادی در نظر گرفته شده است؛ بدین صورت که گوینده ها (مرد-مرد)، (زن-زن) و یا (زن-مرد) می باشند. در هر حالت، دو آزمایش مختلف با صداهای متفاوت انجام می شود.

در این قسمت، روش پیشنهادی با دو روش [۳۷] و [۴۰] (که در فصل دوم نیز به آن ها اشاره شده است) مقایسه می شود. مرجع [۳۷] به جداسازی بدون نظارت دو گوینده همزمان پرداخته است که بلوک دیاگرام این روش در شکل (۵-۱) نشان داده شده است؛ این روش مبتنی بر ویژگی و بدون نظارت می باشد. مطابق با اطلاعات موجود در [۳۷] و بلوک دیاگرام شکل (۵-۱)، از روش مبتنی بر ویژگی CASA و ماسک های باینری تخمین زده شده برای جداسازی استفاده شده است. همانطور که قبلاً نیز اشاره شد، CASA در قسمت آنالیز پیرامونی اغلب از دو حالت تبدیل فوریه یا فیلتربانک گاماتون برای جداسازی استفاده می کند که در [۳۷] از فیلتربانک گاماتون به عنوان روش استخراج ویژگی استفاده کرده است. مرجع [۴۰] از روش مبتنی بر مدل و از طریق یک الگوریتم تکراری، دو گوینده همزمان را جدا می کند. البته در این روش هم از یک ماسک باینری به منظور تخمین سیگنال خروجی استفاده شده است.




شکل (۱-۵) بلوک دیاگرام پیشنهادی برای سیستم جداسازی دو گوینده همزمان [۳۷]

۵-۴-۱- آزمایش اول و دوم دو گوینده هم جنس (مرد-مرد)

در این بخش، از دو گوینده هم جنس مرد برای انجام شبیه سازی به منظور جداسازی روش پیشنهادی و روش های موجود در [۳۷] و [۴۰] استفاده شده است. شکل های (۲-۵) و (۳-۵) نتایج مقایسه شکل موج خروجی روش پیشنهادی با الگوریتم های [۳۷] و [۴۰] را نشان می دهند. تفاوت آزمایش ها در جملات گفته شده و گویندگان آن ها می باشد، به طوری که در هر آزمایش گوینده و جمله ی گفته شده متفاوت می باشد. جملاتی که هر کدام از گویندگان به زبان می آورند، در قسمت زیرنویس شکل به صورت خلاصه آورده شده است.


به صورت کلی در قسمت (a) هر کدام از شکل ها، صدای مخلوط دو گوینده نشان داده شده است. در قسمت (b) و (c)، صدا های تمیز ورودی مربوط به هر کدام از گویندگان قبل از مخلوط شدن آورده شده است. قسمت (d) و (e)، نتایج روش پیشنهادی را نشان می دهد و قسمت (f) و (g)، نتایج [۳۷] را نشان می دهد. در قسمت (h) و (i)، نتایج جداسازی روش [۴۰] آورده شده است.

در این بخش در آزمایش اول، جمله گفته شده گوینده اول (مرد)، "bin blue at F 4 again" و جمله گفته شده گوینده دوم (مرد)، "set green at C 2 now" می باشد. شکل موج خروجی در شکل (۲-۵) آورده شده است.



شکل (۵-۲) مقایسه شکل موج صدای جداسازی شده آزمایش اول (مرد-مرد)، جمله‌ی گفته شده توسط گوینده اول "bbaf4a" و جمله‌ی گفته شده توسط گوینده دوم "sgaczn" می باشد. در تمام شکل‌ها محور افقی نمونه و محور عمودی دامنه می باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰]. در این آزمایش روش [۳۷] نتوانست به درستی جداسازی را انجام دهد.

در آزمایش دوم، جمله گفته شده گوینده اول (مرد)، "lay blue with R 1 now" و جمله گفته شده گوینده دوم (مرد)، "place red by C 8 now" می‌باشد. شکل موج خروجی در شکل (۵-۳) آورده شده است.



شکل (۵-۳) مقایسه شکل موج صدای جداسازی شده آزمایش دوم (مرد-مرد)، جمله‌ی گفته شده توسط گوینده اول "lbwr1n" و جمله‌ی گفته شده توسط گوینده دوم "prbc8n" می‌باشد. در تمام شکل‌ها محور افقی نمونه و محور عمودی دامنه می‌باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰] (h) صدای جداسازی شده نخست توسط روش [۳۷] (i) صدای جداسازی شده دوم توسط روش [۳۷]

همانطور که از این آزمایش‌ها پیداست، شکل موج خروجی روش پیشنهادی به مقدار بسیار زیادی به صداها صاف و ورودی نزدیک‌تر است. این نکته در تمام شکل موج‌های خروجی بخش‌های بعدی نیز صادق است. در واقع، روش پیشنهادی در مقایسه با دو روش موجود، عملکرد بهتری را از خود نشان داده است. همچنین قابل ذکر است که در آزمایش اول، روش بدون نظارت در [۳۷] نتوانست عملیات جداسازی را انجام دهد.

۵-۴-۲- آزمایش سوم و چهارم دو گوینده غیر هم‌جنس (مرد-زن)

در این بخش از دو گوینده غیر هم‌جنس مرد و زن برای انجام آزمایش‌ها و نتایج شبیه‌سازی استفاده شده است.

در این بخش در آزمایش سوم، جمله گفته شده گوینده اول (مرد)، "bin blue at F 4 again" و جمله گفته شده گوینده دوم (زن)، "lay white at D 6 place" می‌باشد.


در آزمایش چهارم، جمله گفته شده گوینده اول (مرد)، "place red by C 8 now" و جمله گفته شده گوینده دوم (زن)، "bin red in R 3 soon" می‌باشد. نتایج در شکل‌های (۴-۵) و (۵-۵) آورده شده است.

۵-۴-۳- آزمایش پنجم و ششم دو گوینده هم‌جنس (زن-زن)


در این بخش از دو گوینده هم‌جنس زن برای انجام آزمایش‌ها و نتایج شبیه‌سازی استفاده شده است.

در این بخش در آزمایش پنجم، جمله گفته شده گوینده اول (زن)، "bin red in R 3 soon" و جمله گفته شده گوینده دوم (زن)، "lay white at D 6 place" می‌باشد.


در آزمایش ششم، جمله گفته شده گوینده اول (زن) "set blue by M 9 again" و جمله گفته شده گوینده دوم (زن) "set white with U 2 now" می‌باشد. نتایج در شکل‌های (۶-۵) و (۷-۵) آورده شده است. در ادامه شکل موج‌های مربوط به هر آزمایش به ترتیب نشان داده شده است.




شکل (۴-۵) مقایسه شکل موج صدای جداسازی شده آزمایش سوم (مرد-زن) ، جمله‌ی گفته شده توسط گوینده اول "bbaf4a" و جمله‌ی گفته شده توسط گوینده دوم "lwad6p" می باشد. در تمام شکل‌ها محور افقی نمونه و محور عمودی دامنه می باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰] (h) صدای جداسازی شده نخست توسط روش [۳۷] (i) صدای جداسازی شده دوم توسط روش [۳۷]



شکل (۵-۵) مقایسه شکل موج صدای جداسازی شده آزمایش چهارم (مرد-زن) ، جمله‌ی گفته شده توسط گوینده اول "prbc8n" و جمله‌ی گفته شده توسط گوینده دوم "brir3s" می باشد. در تمام شکل‌ها محور افقی نمونه و محور عمودی دامنه می باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰] (h) صدای جداسازی شده نخست توسط روش [۳۷] (i) صدای جداسازی شده دوم توسط روش [۳۷]




شکل (۵-۶) مقایسه شکل موج صدای جداسازی شده آزمایش پنجم (زن-زن) ، جمله‌ی گفته شده توسط گوینده اول "brir3s" و جمله‌ی گفته شده توسط گوینده دوم "lwad6p" می باشد. در تمام شکل‌ها محور افقی نمونه و محور عمودی دامنه می باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰] (h) صدای جداسازی شده نخست توسط روش [۳۷] (i) صدای جداسازی شده دوم توسط روش [۳۷]



شکل (۵-۷) مقایسه شکل موج صدای جداسازی شده آزمایش ششم (زن-زن) ، جمله‌ی گفته شده توسط گوینده اول "sbbm9a" و جمله‌ی گفته شده توسط گوینده دوم "swwu2n" می باشد. در تمام شکل‌ها محور افقی نمونه و محور عمودی دامنه می باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰] (h) صدای جداسازی شده نخست توسط روش [۳۷] (i) صدای جداسازی شده دوم توسط روش [۳۷]

در شکل (۵-۸) اسپکتروگرام صدای خروجی تمام روش‌های آزمایش ششم (زن-زن) آورده شده است. با توجه به شکل مشاهده می‌شود که روش پیشنهادی، واحدهای زمان-فرکانسی را بسیار بهتر از سایر روش‌ها جداسازی کرده است. در واقع اسپکتروگرام جمله جداسازی شده توسط روش پیشنهادی، نسبت به روش [۳۷،۴۰]، شباهت بیشتری به شکل‌های مربوط به جمله‌ی تمیز ورودی دارد.




شکل (۵-۸) مقایسه اسپکتروگرام صدای جداسازی شده آزمایش ششم (زن-زن)، جمله‌ی گفته شده توسط گوینده اول "sbbm9a" و جمله‌ی گفته شده توسط گوینده دوم "swwu2n" می‌باشد. (a) صدای مخلوط (b) صدای تمیز اول (c) صدای تمیز دوم (d) صدای جداسازی شده نخست توسط روش پیشنهادی (e) صدای جداسازی شده دوم توسط روش پیشنهادی (f) صدای جداسازی شده نخست توسط روش [۴۰] (g) صدای جداسازی شده دوم توسط روش [۴۰] (h) صدای جداسازی شده نخست توسط روش [۳۷] (i) صدای جداسازی شده دوم توسط روش [۳۷]

۵-۴-۴- مقایسه روش پیشنهادی با سایر روش‌ها

در این بخش نتایج حاصل از مقایسه روش پیشنهادی با روش‌های Hu & Wang در [۳۷، ۴۰]، به- ازای انجام هر شش آزمایش آورده شده است. همچنین لازم به ذکر است، برای انجام آزمایش‌های مدل Hu & Wang، از صداهای تست به‌کار برده شده در روش پیشنهادی خود، استفاده کردیم؛ به- دلیل این‌که به‌صداهای تست استفاده شده در اصل مقاله دسترسی نداشتیم.

در شکل (۵-۹) نمودار مقایسه‌ی SNR خروجی آورده شده است. همانطور که ملاحظه می‌شود، افزایش قابل توجهی در SNR خروجی سیستم پیشنهادی نسبت به [۴۰، ۳۷] در تمام آزمایش‌ها دیده می‌شود. در این نمودار کاملاً مشخص است که روش پیشنهادی در تمام مراحل، بسیار بهتر از سایر روش‌ها عمل کرده است.



شکل (۵-۹) نمودار مقایسه SNR روش پیشنهادی در مقایسه با سایر روش‌ها

در جدول (۵-۲)، مقدار عددی معیارهای ارزیابی SNR و MSE در آزمایش‌های مختلف برای مقایسه نشان داده شده است.


جدول (۵-۲) مقایسه MSE و SNR روش پیشنهادی با سایر روش‌ها

الگوریتم [۳۷]		الگوریتم [۴۰]		روش پیشنهادی		
MSE	SNR	MSE	SNR	MSE	SNR	
-	-	0.0629	-0.1173	0.0277	3.8143	آزمایش ۱ (مرد-مرد)
0.0584	0.0105	0.0574	-0.2433	0.0277	3.2505	آزمایش ۲ (مرد-مرد)
0.1124	0.0827	0.1128	0.0882	0.0111	9.3489	آزمایش ۳ (مرد-زن)
0.0686	-0.1571	0.0633	0.3569	0.0103	7.5055	آزمایش ۴ (مرد-زن)
0.1050	0.1291	0.1054	-0.0140	0.0119	12.5181	آزمایش ۵ (زن-زن)
0.2408	-0.0529	0.2388	-0.0150	0.0317	11.4532	آزمایش ۶ (زن-زن)


۵-۴-۵- انجام آزمایش‌ها تحت شرایط نویزی

به منظور مقایسه رفتار روش پیشنهادی با سایر روش‌ها، در حالتی که صدای ورودی نویزی باشد، آزمایش جدیدی را طراحی می‌کنیم. در این آزمایش جمله‌ی گفته شده توسط گوینده اول، "prbc8n" و جمله‌ی گفته شده توسط گوینده دوم، "brir3s" می‌باشد. در این آزمایش گوینده اول، مرد و گوینده دوم، زن می‌باشد. به صدای مخلوط نویز سفید گوسی با SNR -۵ دسی‌بل، ۰ دسی‌بل و ۵ دسی‌بل اضافه شده است. در این بخش علاوه بر روش‌های [۴۰، ۳۷]، برای مقایسه از مرجع [۳۲] نیز استفاده کرده‌ایم. البته لازم به ذکر است که، این قسمت در آزمایش‌های ما انجام نشده است و فقط از نتایج آن استفاده کرده‌ایم. در [۳۲] برای جداسازی از پایگاه داده Cooke استفاده کرده است؛ در حالی که ما از پایگاه داده SSC به منظور جداسازی استفاده نمودیم. جملات ادا شده متفاوت می‌باشند. شایان ذکر است که فقط به منظور مقایسه و استاندارد، (البته در دو شرایط متفاوت) این قسمت از مرجع [۳۲] اضافه شده است. مطابق اطلاعات درج شده در [۳۲]، تحت شرایط نویزی -۵ دسی‌بل، ۰ دسی‌بل و ۵ دسی‌بل، نتایج حاصل از SNR خروجی به ترتیب: ۳/۷۲ دسی‌بل، ۴/۷۵ دسی‌بل و ۶/۸۵ دسی‌بل شده است.

نتایج آزمایش تحت شرایط نویزی، قبل و بعد از پس پردازش به منظور مقایسه روش پیشنهادی با مدل های Hu & Wang [۳۷،۴۰] و [۳۲]، در شکل های (۵-۱۰) و (۵-۱۱) نشان داده شده است. شکل (۵-۱۰)، نمودار میله ای حاصل از نتایج عددی روش پیشنهادی بعد از پس پردازش با روش های [۳۲،۳۷،۴۰] را نشان می دهد.



شکل (۵-۱۰) مقایسه SNR ورودی بر حسب خروجی تحت شرایط نویزی (میله ای) در شکل (۵-۱۱)، نمودار مقایسه SNR ورودی نسبت به SNR خروجی (که مطابق با فرمول (۵-۱) به دست آمده اند)، به صورت خطی نشان داده شده است. توجه گردد در این حالت، نتایج روش پیشنهادی قبل از پس پردازش نیز در نظر گرفته شده است. همانطور که مشاهده می شود، روش پیشنهادی نسبت به سایر روش ها از جایگاه بهتری برخوردار است.



شکل (۵-۱۱) نمودار مقایسه SNR ورودی برحسب خروجی تحت شرایط نویزی (خطی)

جدول (۵-۳) نتایج آزمایش این بخش را به صورت عددی نشان می دهد. با توجه به جدول (۵-۳) مشاهده می شود که روش پیشنهادی با توجه به معیارهای MSE و SNR از جایگاه بهتر و بالاتری نسبت به سایر روش ها برخوردار است.

جدول (۵-۳) مقایسه MSE و SNR صدای جداسازی شده ی روش پیشنهادی با سایر روش ها

الگوریتم [۴۰]		الگوریتم [۳۷]		روش پیشنهادی قبل از پردازش		روش پیشنهادی بعد از پردازش		Input SNR
						MSE	SNR	
MSE	SNR	MSE	SNR	MSE	SNR	MSE	SNR	-5 db
0.111	0.201	0.113	0.005	0.056	10.873	0.0125	15.77	-5 db
0.110	0.183	0.103	0.668	0.090	0.765	0.0706	1.56	0 db
0.112	0.194	0.108	0.40	0.067	7.941	0.0188	11.85	5 db

۵-۵- نتیجه گیری

در یک مهمانی، ما می توانیم به یک صدای خاص توجه داشته باشیم و دیگر صداهای تداخلی موجود در محیط اطراف خود را فیلتر نماییم. این قابلیت ادراکی، باعث ایجاد انگیزه ای برای پدید

آوردن یک زمینه مطالعاتی جدید گردید. هدف این زمینه مطالعاتی، طراحی سیستم‌های جداسازی گفتار بر اساس اصول سیستم شنوایی انسان است. در بسیاری از کاربردها نظیر بازشناسی گفتار اتوماتیک و مخابرات راه دور، به یک سیستم موثر که توانایی جداسازی سیگنال گفتار هدف از سیگنال تداخلی را در شرایط تک‌میکروفون داشته باشد، نیاز می‌باشد.

در این پایان‌نامه یک روش تلفیقی از روش یادگیری آماری و مبتنی بر ویژگی، برای جداسازی صدای دو گوینده‌ی همزمان از یک صدای مخلوط بیان شد. یکی از چالش‌های موجود در این حوزه، جداسازی صدای گوینده‌های هم‌جنس می‌باشد. با توجه به این که اکثر روش‌های موجود، از تخمین فرکانس گام برای جداسازی صدا استفاده می‌نمایند و گام گوینده‌های هم‌جنس بسیار نزدیک به هم می‌باشد، بنابراین در این حالت روش‌های موجود با مشکل روبرو می‌شوند. در روش پیشنهادی ما محدودیت فرکانس گام وجود ندارد. همانطور که در بخش نتایج شبیه‌سازی دیده شد، روش پیشنهادی قادر است صدای گوینده‌های هم‌جنس را نیز به خوبی گوینده‌های غیر هم‌جنس جدا کند. نوآوری روش پیشنهادی، مدل‌سازی صدای گوینده‌های مختلف با استفاده از آموزش دیکشنری است. از مزایای روش پیشنهادی در این پایان‌نامه، محدود نبودن فرکانس جداسازی می‌باشد. در واقع روش موجود، به فرکانس‌های بالا و پایین، وابسته نیست. البته یکی از مشکلات موجود در این پایان‌نامه در دسترس نبودن پایگاه‌های داده با صدای ضبط شده بسیار زیاد از هر گوینده خاص است. به دلیل وجود الگوریتم یادگیری و آموزش، ما برای هر گوینده به تعداد زیادی صدای ضبط شده از همان گوینده نیاز داریم که فقط پایگاه داده SSC این شرایط را دارا می‌باشد.

در روش پیشنهادی، از خواص تبدیل فوریه زمان کوتاه برای جداسازی سیگنال صوتی استفاده شده است. روش پیشنهادی یک روش با نظارت می‌باشد. همانطور که توضیح داده شد، در روش پیشنهادی ابتدا نمونه‌های صدای گوینده‌ها مدل‌سازی می‌شود. این مدل‌سازی به وسیله‌ی آموزش یک دیکشنری و به دست آوردن بردارهای پایه‌ی مربوط به هر کدام از گوینده‌ها انجام می‌شود. بعد از مدل‌سازی صدای هر کدام از گوینده‌ها، برای هر صدا، مولفه‌های فرکانسی مربوط به هر کدام از دو گوینده

همزمان جداسازی می‌شود. به‌منظور کاهش نویز صدای خروجی و حذف مولفه‌های فرکانسی سیگنال‌های تداخل، یک مرحله‌ی پس‌پردازش نیز روی صدای خروجی انجام می‌شود. نتایج خروجی نشان می‌دهد که روش پیشنهادی، طبق معیار ارزیابی SNR (نسبت سیگنال به نویز) و MSE (خطای میانگین مربعات) برتری محسوس نسبت به سایر روش‌های مبتنی بر ویژگی و مدل بررسی شده در این پایان‌نامه دارد.

۵-۶- کارهای آتی

- ❖ در روش پیشنهادی از تبدیل فوریه زمان کوتاه به‌عنوان استخراج ویژگی در جداسازی استفاده شده است. به‌نظر می‌رسد استفاده از تبدیلات دیگر مثل موجک هم بتواند در این زمینه مفید باشد.
- ❖ پایگاه داده‌های آموزشی موجود بسیار کوچک می‌باشند، تهیه‌ی پایگاه داده‌ای بزرگ، به‌منظور آموزش بهتر دیکشنری و جامع‌سازی الگوریتم، ضروری به‌نظر می‌رسد.
- ❖ هر چند معیار SNR معمول‌ترین روش مقایسه‌ی عددی در الگوریتم‌های جداسازی صدا می‌باشد، اما این الگوریتم قادر نیست تمام خواص دو سیگنال را مقایسه کند. بنابراین ارائه‌ی یک معیار مناسب برای مقایسه روش‌های جداسازی صدا ضروری می‌باشد.
- ❖ در سیستم‌های جداسازی، اصطلاح "هدف" به سیگنال‌های گفتاری نسبت داده می‌شود که، هدف ما جداسازی آن‌ها از بقیه سیگنال‌ها می‌باشد. در عمل، تصمیم‌گیری در مورد این‌که کدام منبع صوتی به‌عنوان منبع هدف در نظر گرفته شود، وابسته به سیستم می‌باشد. حتی هنگامی که هدف از قبل نیز مشخص باشد، تصمیم‌گیری در مورد این‌که کدام سیگنال جدا شده متعلق به منبع هدف می‌باشد، برای سیستم‌ها مسأله ساده‌ای نمی‌باشد. به‌عنوان مثال اگر هدف، جداسازی سیگنال گفتار یک گوینده از گوینده دیگری باشد، باید مشخص گردد که

کدام گوینده، هدف مورد نظر است. یک موضوع برای تحقیقات آینده به کارگیری یک سیستم بازشناسی گوینده برای حل این مشکل است.

❖ یکی دیگر از موضوعات مهمی که باید قبل از به کارگیری سیستم‌های جداسازی گفتار در محیط‌های واقعی مورد بررسی قرار گیرد، انعکاس است. انعکاس باعث ایجاد چالش‌های بسیاری در زمینه جداسازی می‌شود. بنابراین، در نظر گرفتن انعکاس در زمینه جداسازی می‌تواند یک موضوع برای تحقیقات آینده محسوب شود.

مراجع

- [1] Benesty, J., Chen, J., Huang, Y., & Dmochowski, J. (2007), "On microphone-array beamforming from a MIMO acoustic signal processing perspective," *IEEE Transactions on Audio, Speech, and Language Processing*, 15(3), 1053-1065.
- [2] Ephraim, Y., & Malah, D. (1984), "Speech enhancement using a minimum-mean square error short-time spectral amplitude estimator," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 32(6), 1109-1121.
- [3] Jensen, J., & Hansen, J. H. (2001), "Speech enhancement using a constrained iterative sinusoidal model," *IEEE Transactions on Speech and Audio Processing*, 9(7), 731-740.
- [4] Ephraim, Y., Malah, D., & Juang, B. H. (1989), "On the application of hidden Markov models for enhancing noisy speech," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(12), 1846-1856.
- [5] Bregman, A. S. (1994), "Auditory scene analysis: The perceptual organization of sound," MIT press.
- [6] Hu, G., & Wang, D. (2006), "An auditory scene analysis approach to monaural speech segregation," *Topics in acoustic echo and noise control*, 485-515.
- [7] Madhu, N., & Martin, R. (2011), "A versatile framework for speaker separation using a model-based speaker localization approach," *IEEE Transactions on Audio, Speech, and Language Processing*, 19(7), 1900-1912.
- [8] Roman, N., Wang, D., & Brown, G. J. (2003), "Speech segregation based on sound localization," *The Journal of the Acoustical Society of America*, 114(4), 2236-2252.
- [9] Wang, D., & Brown, G. J. (2006), *Computational auditory scene analysis: Principles, algorithms, and applications*, Wiley-IEEE Press, NewYork.
- [10] Shao, Y., Srinivasan, S., Jin, Z., & Wang, D. (2010), "A computational auditory scene analysis system for speech segregation and robust speech recognition," *Computer Speech & Language*, 24(1), 77-93.
- [11] Hyvärinen, A., & Oja, E. (2000). "Independent component analysis: algorithms and applications," *Neural networks*, 13(4), 411-430.
- [12] Jang, G. J., & Lee, T. W. (2003). "A maximum likelihood approach to single-channel source separation," *Journal of Machine Learning Research*, 4(Dec), 1365-1392.
- [13] Pedersen, M. S., Wang, D., Larsen, J., & Kjems, U. (2005, September). "Overcomplete blind source separation by combining ICA and binary time-frequency masking," In *IEEE International Workshop on Machine Learning for Signal Processing* (pp. 15-20).
- [14] Davies, M. E., & James, C. J. (2007). "Source separation using single channel ICA," *Signal Processing*, 87(8), 1819-1832.
- [15] Roweis, S. T. (2000, November). "One microphone source separation," In *NIPS* (Vol. 13, pp. 793-799).
- [16] Jordan, F. R. B. M. I. (2005). "Blind one-microphone speech separation: A spectral learning approach," In *Advances in Neural Information Processing Systems 17: Proceedings of the Conference* (Vol. 17, p. 65). MIT Press.

- [17] Ellis, D. P., & Weiss, R. J. (2006, May). " Model-based monaural source separation using a vector-quantized phase-vocoder representation," In *IEEE International Conference on Acoustics Speech and Signal Processing Proceedings* (Vol. 5, pp. V-V). IEEE.
- [18] Schmidt, M. N., & Olsson, R. K. (2006, September). "Single-channel speech separation using sparse non-negative matrix factorization," In *Spoken Language Processing, ISCA International Conference on (INTERSPEECH)*.
- [19] Laurberg, H. (2007, August). "Uniqueness of non-negative matrix factorization," In *IEEE/SP 14th Workshop on Statistical Signal Processing*.
- [20] Virtanen, T. (2007). "Monaural sound source separation by nonnegative matrix factorization with temporal continuity and sparseness criteria," *IEEE Transactions on Audio, Speech, and Language Processing*, 15(3), 1066-1074.
- [21] Benaroya, L., Bimbot, F., & Gribonval, R. (2006). "Audio source separation with a single sensor," *IEEE Transactions on Audio, Speech, and Language Processing*, 14(1), 191-199.
- [22] Schmidt, M. N., & Laurberg, H. (2008). "Nonnegative matrix factorization with Gaussian process priors," *Computational intelligence and neuroscience*, 3.
- [23] King, B., & Atlas, L. (2010, March). "Single-channel source separation using simplified-training complex matrix factorization," In *IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 4206-4209). IEEE.
- [24] Morgan, D. P., George, E. B., Lee, L. T., & Kay, S. M. (1997). "Cochannel speaker separation by harmonic enhancement and suppression," *IEEE Transactions on Speech and Audio Processing*, 5(5), 407-424.
- [25] Stubbs, R. J., & Summerfield, Q. (1990). "Algorithms for separating the speech of interfering talkers: Evaluations with voiced sentences, and normal-hearing and hearing-impaired listeners," *The Journal of the Acoustical Society of America*, 87(1), 359-372.
- [26] Eldin, A. M. M., & Youssif, A. A. (2013). "A Hybrid Approach for Co-Channel Speech Segregation based on CASA, HMM Multipitch Tracking, and Medium Frame Harmonic Model," *arXiv preprint:1312.4127*.
- [27] Hu, G., & Wang, D. (2004). "Monaural speech segregation based on pitch tracking and amplitude modulation," *IEEE Transactions on Neural Networks*, 15(5), 1135-1150.
- [28] Virtanen, T., & Klapuri, A. (2001). "Separation of harmonic sounds using multipitch analysis and iterative parameter estimation," In *Applications of Signal Processing to Audio and Acoustics, IEEE Workshop on the* (pp. 83-86).
- [29] Holdsworth, J., Nimmo-Smith, I., Patterson, R., & Rice, P. (1988). "Implementing a gammatone filter bank," *Annex C of the SVOS Final Report: Part A: The Auditory Filterbank*, 1, 1-5.
- [30] Mahmoodzadeh, A., Abutalebi, H. R., Soltanian-Zadeh, H., & Sheikhzadeh, H. (2012). "Single channel speech separation in modulation frequency domain based on a novel pitch range estimation method," *EURASIP Journal on Advances in Signal Processing*, (1), 1-10.

- [31] Slaney, M., & Lyon, R. F. (1993). "On the importance of time-a temporal representation of sound," *Visual representations of speech signals*, 95-116.
- [۳۲] گراوانچی زاده، م، ایمانی شاملو، ص، (۱۳۹۳). "جداسازی تک‌گوشی گفتار صدادار مبتنی بر روش‌های جدید انتخاب واحدهای زمان-فرکانس در فرکانس‌های پایین و بالا" *مجله مهندسی برق دانشگاه تبریز*، ۴۳(۱)، ۵۱-۶۳.
- [33] Weintraub, M. (1985). "A theory and computational model_ of auditory monaural sound separation," (Doctoral dissertation, Stanford University).
- [34] Cooke, M. (2005). "Modelling auditory processing and organisation (Vol. 7)," Cambridge University Press.
- [35] Brown, G. J., & Cooke, M. (1994). "Computational auditory scene analysis," *Computer Speech & Language*, 8(4), 297-336.
- [36] Parsons, T. W. (1976). "Separation of speech from interfering speech by means of harmonic selection," *The Journal of the Acoustical Society of America*, 60(4), 911-918.
- [37] Hu, K., & Wang, D. (2013). "An unsupervised approach to cochannel speech separation," *IEEE Transactions on Audio, Speech, and Language Processing*, 21(1), 122-131.
- [38] Hu, G., & Wang, D. (2010). "A tandem algorithm for pitch estimation and voiced speech segregation," *IEEE Transactions on Audio, Speech, and Language Processing*, 18(8), 2067-2079.
- [۳۹] گراوانچی زاده، م، دادور، پ، (۱۳۹۵). "تخمین SNR ورودی با استفاده از ماسک باینری در سیستم‌های مبتنی بر آنالیز ترکیب شنیداری محاسباتی" *مجله مهندسی برق دانشگاه تبریز*.
- [40] Hu, K., & Wang, D. (2013). "An iterative model-based approach to cochannel speech separation," *EURASIP Journal on Audio, Speech, and Music Processing*, (1), 1-11.
- [41] Schimmel, S. M. (2007). "Theory of modulation frequency analysis and modulation filtering, with applications to hearing devices," (Doctoral dissertation, University of Washington).
- [42] Won, J. H., Schimmel, S. M., Drennan, W. R., Souza, P. E., Atlas, L., & Rubinstein, J. T. (2008). "Improving performance in noise for hearing aids and cochlear implants using coherent modulation filtering," *Hearing research*, 239(1), 1-11.
- [۴۳] محمودزاده، آ، (۱۳۹۱)، رساله دکتری: "توسعه روش‌های مبتنی بر ویژگی برای جداسازی دو گوینده همزمان"، دانشکده برق و کامپیوتر، دانشگاه یزد
- [44] Meddis, R., & Hewitt, M. J. (1991). "Virtual pitch and phase sensitivity of a computer model of the auditory periphery. I: Pitch identification," *The Journal of the Acoustical Society of America*, 89(6), 2866-2882.

- [45] Lee, Y. K., Kwak, C., Lee, I. S., & Kwon, O. W. (2010, June). "Single-channel speech separation using zero-phase models," In *IEEE International Symposium on Consumer Electronics (ISCE)* (pp. 1-4). IEEE.
- [46] Licklider, J. C. R. (1951). "A duplex theory of pitch perception," *The Journal of the Acoustical Society of America*, 23(1), 147-147.
- [47] Tolonen, T., & Karjalainen, M. (2000). "A computationally efficient multipitch analysis model," *IEEE transactions on speech and audio processing*, 8(6), 708-716.
- [48] Bach, F. R., & Jordan, M. I. (2005, March). "Discriminative training of hidden markov models for multiple pitch tracking [speech processing examples]," In *Proceedings.(ICASSP'05). IEEE International Conference on Acoustics, Speech, and Signal Processing*, (Vol. 5, pp. v-489). IEEE.
- [49] Klapuri, A. (2008). "Multipitch analysis of polyphonic music and speech signals using an auditory model," *IEEE Transactions on Audio, Speech, and Language Processing*, 16(2), 255-266.
- [50] Deller Jr, J. R., Proakis, J. G., & Hansen, J. H. (1993). "Discrete time processing of speech signals," Prentice Hall PTR.
- [51] Aharon, M. Elad, A. Bruckstein, M. (2006). "The K-SVD: An Algorithm for Designing of Overcomplete Dictionaries for Sparse Representations," *IEEE Trans. Signal Process*, vol. 54, no. 11, pp. 4311-4322.
- [52] Donoho, D.L, Tsaig, Y., Drori, I., & Starck, J.L., (2012). "Sparse Solution of Underdetermined Systems of Linear Equations by Stagewise Orthogonal Matching Pursuit," *IEEE Trans. Inf. Theory*, vol. 58, no. 2, pp. 1094-1121.
- [53] Pati, Y. C., Rezaiifar, R., & Krishnaprasad, P. S. (1993, November). "Orthogonal matching pursuit: Recursive function approximation with applications to wavelet decomposition", In *Signals, Systems and Computers, Conference Record of The Twenty-Seventh Asilomar Conference on* (pp. 40-44). IEEE.
- [54] Cooke, M. Lee, T., Speech Separation Challenge (21 September 2006). [<http://staffwww.dcs.shef.ac.uk/people/M.Cooke/SpeechSeparationChallenge.htm>]

واژه‌نامه انگلیسی به فارسی

A

Automatic Speech Recognition سیستم بازشناسی خودکار گفتار
Auditory Scene Analysis تحلیل صحنه شنیداری
Autocorrelation Function تابع خودهمبستگی

B

Best-Fitting بهترین جاسازی
Blind Source Separation جداسازی کور منابع

C

Carrier Estimator تخمین‌گر حامل
Cepstral Filter فیلتر کپسترال
Cepstrum کپستروم
Clustering خوشه‌بندی
Cochleagram گوش حلزونی
Cocktail-party کوکتل-پارتی
Complementary Binary Masks ماسک‌های باینری مکمل
Complex Cepstrum کپستروم مختلط
Computational Auditory Scene Analysis آنالیز محاسباتی نمایش شنوایی
Correlogram همبستگی نگاشت

D

Decreasing Periodicity کاهش یافتن تناوب

E

Energy Sparsity پراکندگی انرژی
Enhanced Envelope Autocorrelation Function تابع خودهمبستگی پوش بهبودیافته
Envelope Autocorrelation Function تابع خودهمبستگی پوش

F

Feature-Based	مبتنی بر ویژگی
Formants	فورمنت‌ها
Frequency Proximity	مجاورت فرکانسی
Full rank	رتبه کامل
G	
Gammatone Filterbank.....	فیلتربانک گاماتون
Grouping	گروه‌بندی
H	
Harmonic Magnitude Suppression	تکنیک حذف دامنه هارمونیک
Harmonic Sieve	الک طیفی
Harmonicity	هارمونیک بودن
Hidden Markov Model	مدل مارکف مخفی
Hilbert Envelope	پوش هیلبرت
I	
Ideal Binary Mask	ماسک باینری ایده‌آل
Increasing Periodicity	افزایش به سمت تناوب
Independent Component Analysis	آنالیز مولفه‌های مستقل
Independent Subspace Analysis	آنالیز زیرفضای مستقل
Instantaneous frequency	فرکانس لحظه‌ای
Iterative Algorithm	الگوریتم تکراری
L	
Linear Predictive Analysis	آنالیز پیش‌گویی خطی
Local SNR	نسبت سیگنال به نویز محلی
Local Time	زمان محلی
Location	محل منبع صدا
M	
Magnitude Operator	عملگر تخمین دامنه
Mel	مل
Model-Based	مبتنی بر مدل‌سازی

Multipitch	چند گام
N	
Noise Bursts	نویز ضربه‌ای
Non-negative Matrix Factorization	فاکتورگیری ماتریس نامنفی
Nonstationary	غیرایستایی
O	
Offset	فرود
Onset	فراز
P	
Pitch Detemination Algorithm	الگوریتم تعیین گام
Pitch template	الگوی گام
Pitch	گام
Pretrained	از پیش آموزش داده شده
Prior knowledge	اطلاعات قبلی
Psychoacoustic Observations	مشاهدات روان - آکوستیکی
Pure Tone	تک تن
R	
Real Cepstrum	کپستروم حقیقی
S	
Segmentation	بخش‌بندی
Segmenter	بخش‌بندی کننده
Short Time Fourier Transform	تبدیل فوریه زمان کوتاه
Signal-to-Noise Ratio	نسبت سیگنال به نویز
Spatial Filters	فیلترهای فضایی
Speak Identification	شناسایی گوینده
Spectral Comb	شانه طیفی
Statistical Learning	یادگیری آماری
Sub-Gaussian	زیرگوسی
Summary Correlogram	همبستگی نگاشت مختصر

Super-Gaussian.....	فراگوسی
Supervise	با نظارت
T	
Test	تست
Time-Frequency (T-F) Units	واحدهای زمان – فرکانس
Time-Frequency	زمان – فرکانس
Tone	آهنگ
Training	آموزش
U	
Unsupervised Approach	روش بدون نظارت
Unvoiced Speech	گفتار بی صدا
Utterance-Based Format.....	بر اساس فرمت گفتار
V	
SVocal Tract.....	مجرای گفتار
Voiced Speech.....	گفتار صدادار
Z	
Zero-crossing	محل قطع صفر

Abstract

One of the most important subjects in the field of communication is separating speech by machine that remains as a challenge due to the problems and weaknesses in this system. This is while human hearing system have remarkable abilities in comparison to speech separator machines. Consequently, due to the differences in the operation of speech separator system in machine and human hearing systems, an efficient system for speech separation by machines is indispensable. For instance, one of the disadvantages of automated speech recognizer is its performance decrement in noisy environment. Therefore, such a system have to be equipped with a proper speech separator, not only to improve its performance in different conditions, but also to improve speech quality and reduce non-speech signal transfer cost. As accurate Time-Frequency units selection has a significant impact on separation results, in this thesis we propose a supervised method to select appropriate frequency-time units. In the proposed approach, speakers' speech samples are first modeled via training a dictionary and obtaining fundamental vectors related to each speaker. After modeling two synchronous speakers' speeches, separation operation is done for each speech according to its frequency component. Furthermore, to reduce noise and to remove irrelevant frequency components, a post processing step is also carried out on the output speech.

As can be seen from the systems' output results, our proposed method has a considerable improvement in its operation compared to other feature-based methods.

Keywords- Computational auditory scene analysis (CASA)- cochannel speech separation- supervised segregation.



Shahrood University of Technology
Faculty of Electrical Engineering and Robotics

M.Sc. Thesis in Communication

Speech Separation Of Two Speakers Based on Appropriate Time-Frequency Features

By: **Rana Dehghani**

Supervisor:

Dr. Hossein Marvi

February 2017