

ارائه یک مدل پارامتریک تطبیقی جهت کشف و ردبندی وقایع صوتی در سیگنال‌های محیطی

مراد درخشان^۱، دانشجوی دکتری؛ حسین مروی^۲، دانشیار؛ حمید حسن پور^۳، استاد

۱- دانشکده مهندسی کامپیوتر و فناوری اطلاعات - دانشگاه صنعتی شاهرود - شاهرود - ایران - mderakhshan@shahroodut.ac.ir

۲- دانشکده مهندسی کامپیوتر و فناوری اطلاعات - دانشگاه صنعتی شاهرود - شاهرود - ایران - marvi_hossein@yahoo.co.uk

۳- دانشکده مهندسی کامپیوتر و فناوری اطلاعات - دانشگاه صنعتی شاهرود - شاهرود - ایران - h.hassanpour@shahroodut.ac.ir

چکیده: کشف وقایع صوتی در محیط کار و زندگی یک نیاز مدرن جهت گردآوری اطلاعات است. تاکنون بیشتر تحقیق‌ها بر واقعه صوتی خاص و یا تعداد محدودی از وقایع صوتی برجسته متمرکز بوده‌است. در اینجا یک مدل‌سازی جدید جهت کشف تمام وقایع صوتی رخداده در رکورد و تعیین محدوده زمانی برای هر یک از آن‌ها رائه شده‌است. نوآوری شامل مدل‌سازی جدید همراه با پارامترهای تطبیقی در مدل است. پس از استخراج ویژگی‌ها و تعیین مقادیر دو پارامتر آلفا و بتا از دو قطعه‌بندی مجزا و ترکیب خروجی آن‌ها برای تعیین وقایع صوتی و محدوده زمانی آن‌ها استفاده شده‌است. این وقایع جهت ردبندی به الگوریتم KNN فرستاده می‌شوند. پارامترها امکان دقت بیشتر و یا میزان کشف حداکثری را ممکن می‌سازند. وقایع صوتی آزمایش شده شامل ۱۶ نوع صدای اتاق کار اداری هستند که برخی شبیه هم و بعضی نیز مشابه نویز محیط هستند. در سنجش عملکرد برحسب واقعه، میزان درستی کشف ۷۰/۱ درصد، فراخوانی ۷۵/۸ درصد و میزان F1، ۷۲/۸ درصد بوده‌است. همچنین میزان F1 برحسب فریم ۸۰/۶ درصد حاصل شد. مقدار F1 برحسب واقعه، نسبت به قبل ۱۰/۸٪ بهبود داشته‌است که مovidکارآمدی مدل پیشنهادی است.

واژه‌های کلیدی: کشف وقایع صوتی، صدای محیطی، الگوریتم‌های یادگیری بدون نظارت، سیستم‌های پارامتریک تطبیقی، سیستم‌های نظارت صوتی، سیستم‌های کسب اطلاعات مبتنی بر صدا.

Providing an Adaptive Model with two Adjustable Parameters for Audio Event Detection and Classification in Environmental Signals

Morad Derakhshan, PhD student¹; Hossein Marvi, Associate professor²; Hamid Hassan poor, professor³

1- Computer and IT Engineering Department, Shahrood University of Technology, Shahrood, Iran, mderakhshan@shahroodut.ac.ir

2- Computer and IT Engineering Department, Shahrood University of Technology, Shahrood, Iran, marvi_hossein@yahoo.co.uk

3- Computer and IT Engineering Department, Shahrood University of Technology, Shahrood, Iran, h.hassanpour@shahroodut.ac.ir

Abstract: Audio event detection (AED) is a modern way to collect data about human activities in the workplace or in other life environments. We proposed a novel adaptable model based on using two parameters, α and β to detect all audio events that may be present in a given record accompanied by their time limits in which they occur. After feature extraction and setting the values of the two key parameters, alpha and beta, the audio sequence will be sent into two distinct sub-systems for event detection. The outputs from the two sub-classifiers are then combined and necessary refinements are made on the event time limits. The final detected events are sent to the KNN classifier. The parameters serve as a trade-off tool between precision and recall expectation in the detection process. In the tests, 16 different audio events of an office room were detected, some being similar to each other and some have very similar characteristics to those of the background noise. At frame-based (FB) level, the precision rate was 70.1%, the rate of recall was 75.8%, and F1-measure was 72.8%. The F1-measure has increased by 10.8% suggesting promising applications of the model.

Keywords: Audio event detection (AED), environmental sounds, unsupervised learning, adaptable modeling systems, audio monitoring systems, audio-based acquisition systems.

تاریخ ارسال مقاله: ۱۳۹۶/۰۳/۱۳

تاریخ اصلاح مقاله: ۱۳۹۶/۰۵/۰۷

تاریخ پذیرش مقاله: ۱۳۹۶/۰۷/۰۵

نام نویسنده مسئول: دکتر حسین مروی

نام نویسنده مسئول: ایران - شاهرود - دانشگاه صنعتی شاهرود - دانشکده مهندسی کامپیوتر و فناوری اطلاعات.

۱- مقدمه

انرژی باندهای فرکانسی مل استفاده کرده است. در [۱۷] از شبکه عصبی LSTM-RNN دوسویه به همراه HMM و ۱۰۰ ویژگی از نوع فیلتر بانک فرکانس مل برای هر فریم استفاده نموده اند. در [۱۸] از شبکه های حسگر با چندین محل اخذ صدای محیط و سپس ترکیب و امتزاج اطلاعات و بهره گیری از پشتہ سازی رده بند برای شناسایی میکروفون و محل ارسال صدا استفاده شده است. در [۱۹] از ترکیب شبکه های مصنوعی GRNN با LDA و تعریف یکتابع هدف براساس تابع هزینه ترکیبی از MSE علاوه بر شناسایی واقعی، صحنه صوتی را نیز شناسایی کرده اند.

اما اخیراً روش هایی بر پایه مدل پیوسته سرهنگی دومرحله ای پیشنهاد شده است. از جمله در [۲۰] با هدف استخراج ویژگی های دارای قابلیت جدا کنندگی بالا رویکرد بوستینگ^۱ پیشنهاد شده است و نتایج حاصل نیز نسبت به ویژگی های ادراکی سنتی همچون ضرایب فرکانس^۲ مل و لگاریتم بانک های فیلتر^۳ فرکانس مل بهتر بوده است. این نوع مدل سازی را آماری هرمی^۴ می گویند. همچنین [۲۱] در یک مدل پیوسته دو پشتۀ^۵، مزایای مدل سازی متواالی را با قابلیت های جداسازی پرسپترون چندلایه ترکیب نموده و با اجرای یک مرحله رتبه بندی مجدد (همانند آنچه در بازنگاری گوینده انجام می شود) کارایی رده بندی را از طریق بکار گیری مدل GMM-SVM تقویت کرده است.

ایده اصلی در پژوهش حاضر، یک مدل سازی دارای دو فاز مجزا یکی جهت قطعه بندی و دیگری جهت کشف و رده بندی و قایع در سیگنال ورودی به همراه انجام قطعه بندی در دو زیر سیستم و داشتن پارامترهای مجزا برای آنها است. با این روش مزیت استفاده حداکثری از ویژگی ها و همچنین مدل سازی به صورت تفکیک اجزا بجای مدل سازی یکپارچه و غیرقابل تفکیک دیده شده است. دو زیر سیستم مجزا قابلیت تطبیق الگوریتم با نوع ویژگی های استخراجی را دارد. مزیت اصلی این مدل استفاده هر چه بیشتر از ظرفیت ویژگی های مورد استفاده و ایجاد فضای تصمیم گیری چندشاخه برای تعیین قطعات و همین طور استفاده از قدرت هم افزایی دو زیر سیستم بجای یک سیستم یکپارچه می باشد.

ادامه مقاله به صورت زیر است: بخش ۲ مدل پیشنهادی و اجزای آن، بخش ۳ استخراج ویژگی های جهت الگوریتم کشف و قایع، بخش ۴ قطعه بندی و رده بندی بر حسب مدل پیشنهادی، بخش ۵ اجرای مدل و نتایج آن، بخش ۶ نتیجه گیری، بخش ۷ چند پیشنهاد برای کار آینده.

۲- مدل پیشنهادی و اجزای آن

کشف و قایع صوتی معمولاً در دو فاز انجام می شود. در فاز نخست ابتدا سیگنال قطعه بندی می شود، به طوری که بخش های فریم هایی از سیگنال ورودی که حاوی صدای محیطی هستند شناسایی شوند. فاز دوم کشف و قایع است که طی آن قطعه های جدا شده هم در قالب و قایع صوتی دارای محدوده زمانی شروع و پایان تعیین می شوند و رده بندی

جداسازی و شناسایی یک اتفاق صوتی در محدوده زمانی رخداده برای انسان، کاری آسان و تکراری است، اما انجام آن برای پردازش های ماشینی به عنوان یک چالش اساسی مطرح است و حل آن یکی از اولویت های اصلی انجمن های پردازش صوت می باشد. کاربردهایی همچون نظرات و دیده بانی صوتی در محیط های عمومی، داده کاوی صوتی، درک یک ابزار هوشمند مثل گوشی های تلفن سیار نسبت به محیط اطراف خود و همچنین مراقبت خود کار از افراد بیمار یا سالمند همگی از صوت به عنوان بستر اطلاعات استفاده می کنند.

از پژوهش های گذشته در این حوزه می توان به مطالعه [۱] اشاره نمود که سیستمی را می توان بر رده بندی One-class SVM برای شناسایی ناهنجاری هایی همچون صدای شلیک تفنگ، شکستن شیشه و صدای جیغ ارائه نموده اند. در [۲] یک مدل تطبیق پذیر برای کشف و قایع صوتی کوتاه مدت و دراز مدت و همچنین برای صدای هایی که در زمینه خود نویز مشابه با صدای اصلی دارند، پیشنهاد کردن. پژوهش [۳] به شناسایی مشخصه های صدای شلیک تفنگ پرداخته است. در [۴] به منظور دسته بندی صحنه های شناوی، شناسایی و ایندکس کردن معنایی و قایع صوتی در هر صحنه شناوی انجام شده است. در [۵] با استفاده از مدل نیمه نظراتی بیز و قایع صوتی در رکورد ورودی را رونویسی کرده و قایع چندگانه هم زمان را مورد پردازش قرار داده است. پژوهش [۶] یک مدل احتمالاتی محدود زمانی را برای کشف و قایع استفاده نموده است. در [۷] صحنه های شناوی را از طریق شناسایی صدای های موجود در آن تشخیص می دهد. در رویکرد دسته فرمی [۸] برای هر صدای یک مدل GMM آموزش داده می شود آنگاه تخمینی از مجموع GMM های تمام فریم ها محاسبه شده و رده ای که دارای بالاترین شباهت باشد، انتخاب می شود. در [۹، ۱۰] رویکرد ویژگی های دسته ای پیشنهاد شده است که هیستو گرام حاصل از ویژگی های خوش بندی شده را برای رده بندی استفاده می کند. تحقیق [۱۱] از روش جداسازی سیگنال ها برای تجزیه سیگنال ورودی به و قایع استفاده کرده است. تجزیه نامنفی ماتریس در مدل های دیگری از جمله [۱۲، ۱۳] استفاده شده است. در آنجا سیگنال ورودی مشاهده به دو ماتریس نامنفی تجزیه شده و برای سیگنال آزمایش از یک دیکشنری و قایع استفاده می کنند. در [۱۴] و صله های طیفی از پیش استخراج شده برای تجزیه سیگنال به و قایع استفاده می شود و از تعداد زیادی ویژگی حوزه زمان و فرکانس استفاده نموده است.

سیستم های متعددی عمدتاً بر اساس شبکه های عصبی CNN و RNN به منظور شناسایی صدای های محیطی و شناسایی صحنه های صوتی در DCASE_2016 پیشنهاد شده است که بر روی پایگاه داده یکسان حاوی ۱۱ صدای محیطی بسط داده شده اند [۱۵]. از جمله در [۱۶] شبکه های عصبی عمیق DNN همراه با مدل سازی حذف نویز برای شناسایی و قایع صوتی بکار گرفته شده و از ویژگی های

تعیین یک مقدار آستانه که بتواند شرایط متفاوتی را در انتخاب یا راد فریم‌های صوتی بکار گیرد و یا اینکه میزان کشف و دقیقت کشف را نسبت به هم کنترل نماید، دچار معضل هستند. از سوی دیگر، وجود کمیت‌های مختلف برای آستانه که بتوانند اعداد صحیح، اعشاری و یا مختلط باشند، لزوم استفاده از پارامترهای انعطاف‌پذیر و متفاوت را توجیه‌پذیر می‌کند. برای مثال در فاز پیاده‌سازی این تحقیق پارامتر آلفا از نوع عددی صحیح و پارامتر بتا از نوع عددی اعشاری است. کارکرد این دو پارامتر می‌تواند سبب تراز بین میزان کشف و میزان دقیقت و قایعیگردد. وجود این دو پارامتر انعطاف لازم به هر یک از الگوریتم‌های قطعه‌بندی را می‌دهد تا بتوانند در مورد کمیت آستانه و همچنین مقدار بهینه مورد نظر برای آستانه اقدام کنند.

۳- استخراج ویژگی‌ها جهت الگوریتم کشف و قایع

به دلایلی از جمله سنجش توانایی ویژگی‌های حوزه زمان در کشف تعداد متنوع و قایع صوتی، تحقیق در نحوه تولید دو گروه از ویژگی‌های متفاوت با نوع پارامتر متفاوت و بعلاوه وجود تغییرهای بسیار سریع مشخصه‌های زمانی در وقایع صوتی جهت قطعه‌بندی حوزه زمان انتخاب شده است. پایگاه داده مورد استفاده از تعداد ۱۶ نوع واقعه صوتی مختلف تشکیل شده است که لیست این وقایع در جدول ۱ آمده است.

جدول ۱: انواع وقایع صوتی مورد پردازش در این پژوهش (پایگاه داده ارائه شده توسط انجمن تخصصی پردازش سیگنال صوت در موسسه بنی‌المالی (IEEE)

ردیف	نام واقعه صوتی	توضیحات
۱	alarm	(short alert (beep) sound)
۲	clearthroat	(clearing throat)
۳	cough	
۴	doorslam	(door slam)
۵	Drawer	
۶	keyboard	(keyboard clicks)
۷	keys	(keys put on table)
۸	knock	(door knock)
۹	laughter	
۱۰	mouse	(mouse click)
۱۱	pageturn	(page turning)
۱۲	pendrop	(pen, pencil, or marker touching table surfaces)
۱۳	phone	
۱۴	printer	
۱۵	speech	
۱۶	Switch	

تفاوت بین صدای های حنجره‌ای (گفتاری) و صدای محیطی بحث مهمی است که در اینجا به آن اشاره می‌شود. شکل ۲ نمونه‌ای از تفاوت اطلاعات طیفی بین این دو دسته از صدای را نشان می‌دهد. همان‌گونه که مشخص است از صدای های گفتاری به راحتی می‌توان ساختار فرمتهای و گام را شناسایی و استخراج کرد. اما صدای های محیطی فاقد ساختار طیفی مشخص هستند. لذا در بحث استخراج

قطعات نیز انجام می‌شود. در این حالت چنانچه قطعه‌بندی به خوبی صورت نگیرد کل عملیات کشف و قایع و ردیه‌بندی با خطأ و دقت پایین همراه خواهد بود. بنابراین میزان موفقیت الگوریتم بستگی به مدل‌سازی مناسب، تعیین درست پارامترهای مدل و همچنین انتخاب ویژگی‌هایی دارد که بتواند به خوبی ابعاد تغییرپذیر داده‌ها در رده‌های صوتی مختلف را نمایش دهد. چنانچه تعداد صدای های موجود در کشف و قایع زیاد باشد می‌توان استدلال کرد که ویژگی‌های خاص در صدای های مشخصی سبب تفکیک‌پذیری بهتر می‌شوند، لذا داشتن دو زیر سیستم مجزا ایده منطقی به نظر می‌رسد.

در این مدل ابتدا عملیات اولیه نرمال‌سازی، سفیدکردن داده‌ها و حذف نویز از طریق فیلترینگ بر روی سیگنال اصلی انجام می‌شود. سپس از سیگنال ورودی (X) بردارهای ویژگی موردنظر استخراج می‌شوند. با داشتن بردارهای ویژگی آنها به دو دسته جداگانه تبدیل می‌شوند. این تقسیم‌بندی به دلیل آن است که استفاده هم‌زمان از تمام ویژگی‌های می‌تواند در کشف تعداد زیاد صدای نقص منفی ایفا کنند، به طوری که امکان اینکه ویژگی‌ها اثر متمایز کننده یکدیگر را در الگوریتم خنثی نمایند زیاد است، لذا تبدیل ویژگی‌ها به دو دسته جهت شناسایی بیشتر صدای و ایجاد تمایز بین صدایها بهتر عمل می‌کند. سپس عمل قطعه‌بندی بر روی سیگنال ورودی با دو دسته ویژگی متفاوت انجام می‌شود که این دو نوع قطعه‌بندی می‌توانند دو الگوریتم متفاوت و یا یکسان باشند. الگوریتم قطعه‌بندی با به کارگیری پارامتر آلفا و بتا می‌تواند بین کشف دقیق‌تر و یا کشف بیشتر و قایع مصالحه‌ای را بوجود آورد.


پس از اتمام دو نوع قطعه‌بندی نتایج آنها برای کشف و قایع و یکپارچه‌سازی محدوده هر اتفاق صوتی و بدست آوردن زمان شروع و پایان هر واقعه صوتی مورد استفاده قرار می‌گیرد. در پایان مرحله قطعه‌بندی لیستی از وقایع به همراه زمان رخداد هر کدام از آن‌ها تولید شده است که در رشتة ($X_e(n)$) ذخیره می‌شوند.

یک مکانیزم دیگر برای فراهم نمودن شرایط محلی (local) برای یافتن قطعه‌های احتمالی از وقایع که با خاطر تصمیمات بر حسب شرایط global کشف نشده‌اند اجرا می‌گردد. جهت شروع این مرحله سیگنال مرحله جدید را از طریق رابطه $X_e(n) = X(n) - X_e(n)$ بدست $X_1(n)$ بدست می‌آوریم و عملیات مرحله نخست با شرایط محلی در این مرحله با سیگنال باقیمانده اجرا می‌گردد. اجرای این مکانیزم با هدف کشف بیشتر و دقیق‌تر و قایع انجام می‌شود. رشتة ($X_e(n)$) لیست و قایعی است که با این مکانیزم کشف شده‌اند. نتایج مراحل اول و دوم با هم جمع شده، لیست نهایی و قایع و زمان‌های آن‌ها بدست می‌آید. اجزای مدل پیشنهادی در شکل ۱ آورده شده‌اند.


۱-۲- نقش پارامترها در مدل پیشنهادی

در مدل از دو پارامتر آلفا (α) و بتا (β) جهت تنظیم عملکرد قطعه‌بندی استفاده می‌شود. الگوریتم‌های موجود قطعه‌بندی عموماً از

ویژگی‌ها لازم است از ویژگی‌هایی که بیشتر با ساختار صدای محیطی همخوانی دارند، استفاده شود. برای مثال می‌توان گفت ویژگی‌هایی همچون ضرایب MFCC که در شناسایی گفتار نهادینه شده‌اند چندان مناسب بحث مانیستند. لذا در اینجا ویژگی‌های پیشنهادی بر حسب میزان و قابلیت جداسازی آن‌ها انتخاب شده‌اند.



شکل ۱: بلاک دیاگرام مدل پیشنهادی کشف وقایع صوتی.



شکل ۲: وجود ساختار مشخص طیفی از جمله فرمنتهای گام در صدای گفتاری و عدم ساختار طیفی در صدای محیطی.

به پردازش‌های اولیه تخمین نویز وابسته است. با توجه به عدم وجود اطلاعات مذکور، در اینجا جهت بررسی نویز و همچنین اثرات حذف نویز بر روی پردازش‌های بعدی ابتدا از طریق یک آزمایش از فیلتر با توروث به عنوان پیش‌پردازش جهت حذف نویز استفاده گردید. با آزمایش‌های زیاد مقادیر ایده‌آل برای فرکانس‌های پایین و بالای فیلتر میان‌گذر و همچنین مرتبه فیلتر تعیین شد. نتایج بدست‌آمده نشان داد که استفاده از فیلتر میان‌گذر با توروث مرتبه ۷ با فرکانس پایین

۱-۳- بررسی اثرات نویز و حذف آن

بدون داشتن اطلاعات اولیه از ساختار نویز استفاده از روش‌های برآورد نویزهای ضربه‌ای و حذف آن‌ها با الگوریتم وفقی کار ساده و موثری نخواهد بود [۲۳]. همچنین بهبود کیفیت سیگنال از طریق روش‌های زیرفضا که اخیرا برای نویزهای سفید پیشنهاد شده است [۲۴] نیازمند تجزیه سیگنال به مقادیر منفرد کسری ادرارکی (PCQSV) است که

با تفاوت معنادار نسبت به سایر صداها می‌باشد و همچنین مشخص شد که بعضی از صداها از جمله keys, cough, door slam, clear throat مقدار این ویژگی در فریم‌های ابتدایی زیاد است و بالا بودن این ویژگی می‌تواند برای تشخیص ابتدای صداها موثر باشد. علاوه بر این‌ها مشخص شد که فریم‌های انتهایی برخی از صداها از جمله Page - turn, phone, cough, laughter هستند و به خوبی قابل تشخیص می‌باشند. در شکل ۵ نموداری از مقادیر عبور از صفر ۹۵۰ فریم از صداهای مختلف آمده است. همانطور که مشخص است مقدار این ویژگی در تعداد زیادی از فریم‌ها دارای مقادیر بالا و قابل تفکیک است. در فریم‌های ۹۳-۱۰۴ یک اتفاق صوتی مرکب قابل تشخیص است و همچنین در فریم‌های ۶۲۳-۶۶۵ دو واقعه صوتی مجزا قابل تفکیک و شناسایی هستند. مناسب بودن این ویژگی با رسم نمودار راک^۱ بررسی شد و مشخص گردید این ویژگی قابلیت تفکیک و شناسایی صداهای مورد نظر را تا حد زیادی دارد. راک نموداری است که می‌تواند میزان کارایی یک ردیبدند دوگانه را با تغییر مقدار آستانه نمایش دهد [۲۵].

۳-۳- ویژگی نسبت بالای نرخ عبور از صفر

یک ویژگی مهم تغییرات مقادیر عبور از صفر یا *HZCRR* در تعداد N فریم در یک پنجره ۱ ثانیه‌ای است که در رابطه (۲) آمده است.


$$HZCRR = \frac{1}{2N} \sum_{n=1}^{N-1} [\text{sgn}(Zcr(n)-1.5*avZcr)+1] \quad (2)$$

متغیر n اندیس فریم‌ها و $avZcr$ میزان میانگین عبور از صفر در طول یک پنجره ۱ ثانیه‌ای است و N نیز تعداد کل فریم‌های درون پنجره پردازش است. مقدار ویژگی *HZCRR* همواره عددی از صفر تا حداقل ۱ است. هر چه تعداد فریم‌های با مقدار عبور از صفر بالا بیشتر باشند مقدار این ویژگی به عدد ۱ نزدیکتر می‌شود.


طبق بررسی اکثر صداهای محیطی دارای تغییرپذیری بالا و متغیر در ویژگی عبور از صفر هستند که می‌تواند فریم‌های یک صدای مشخص را از سایر صداها قابل تشخیص نماید. همچنین مشاهده شد که مقادیر این ویژگی در سیگنال گفتار عموماً از یک خط پایه و حداقلی برخوردار است که تقریباً نزدیک به عدد ۵۰ است.

در مورد صداهای دیگر تغییرها یا به طور یکنواخت سریع افزایش یافته و سپس با همان شبکه کم می‌شوند، مانند *Page - turn*, یا اینکه حالت پریودیک با نقطه اوج و یک نقطه سقوط دارند و قبل از هر اوج یک سری مقادیر با تغییرهای کم تکرار می‌شوند و واریانس کمی دارند. به علاوه دامنه مقادیر خیلی نزدیک به عدد مشخصی بین ۲۵۰ تا ۳۰۰ است که برای مثال صدای *Phone* از این گروه هست. در مورد صدای *printer* هم مقادیر کاملاً بدون نظم و ساختار بوده و تصادفی می‌باشند. لذا وجود چنین خواصی در ویژگی‌های یک سری از صداها امکان شناسایی آن‌ها را ممکن می‌سازد.

۷۰۰ هرتز و فرکانس بالای ۱۰۵۰۰ هرتز بیشترین اثر مثبت را در شناسایی فریم‌های صدا از فریم‌های غیرصدا دارد. نتایج این آزمایش در شکل‌های ۳ و ۴ بر حسب میزان (TPR) True-positive rate برای تعیین وضعیت صدا/غیرصدا در فریم‌های آزمایش آورده شده‌است. لذا در عملیات پیش‌پردازش از فیلتر باثوروت میان‌گذر مرتبه ۷ با فرکانس پایین ۷۰۰ هرتز و فرکانس قطع بالای ۱۰۵۰۰ هرتز استفاده شد.



شکل ۳: پاسخ فیلتر باثوروت مرتبه ۷ تعیین فرکانس پایین جهت بیشترین بازدهی در شناسایی فریم‌های صدا. در فرکانس ۷۰۰ هرتز نرخ شناسایی درست فریم‌ها حداقل است.



شکل ۴: پاسخ فیلتر باثوروت مرتبه ۷ تعیین فرکانس بالا جهت بیشترین بازدهی در شناسایی فریم‌های صدا. در فرکانس ۱۰۵۰۰ هرتز نرخ شناسایی درست فریم‌ها حداقل است.

نویز موجود در خارج از این پهنای باند تاثیر منفی بر شناسایی صداهای پایگاه داده داشت.

۳-۲-۳- ویژگی عبور از صفر

مقدار ویژگی عبور از صفر به صورت رابطه (۱) قابل محاسبه است:

$$ZCR = \sum_{n=1}^{N-1} |\text{sgn}(x_n) - \text{sgn}(x_{n+1})| \quad (1)$$

متغیرهای x_n و x_{n+1} نمونه‌های پشت‌سرهم در سیگنال ورودی هستند.تابع sgn برای مقادیر مثبت عدد ۱ و برای مقادیر منفی عدد -۱ تولید می‌کند. با بررسی صداهای مورد پردازش مشخص شد که مقدار این ویژگی در صداهای خاصی از جمله switch, printer, keys, page - turn, alert, keyboard مقدار بالا

برای خیزش معمولاً از یک انرژی بیشتر و ناگهانی نسبت به فریم‌های مجاور در طول ۱ ثانیه برخوردار می‌باشدند.

الگوریتم طبق شکل ۶ اجرا شده و نتیجه اجرا طبق رابطه (۴) است.

$$(4) \quad X_1(n) = X(n) - Xe(n)$$

در رابطه (۴)، $X(n)$ سیگنال اولیه است. $Xe(n)$ بخش‌هایی از سیگنال اولیه است که به عنوان قطعات اولیه و قایع صوتی بدست آمدند و (n) سیگنال باقیمانده است. پس از اتمام الگوریتم، قطعه‌های یافته شده طبق رابطه (۵) تجمعی شده و در فاز نهایی ترکیب می‌شوند.

$$(5) \quad Xe(n) = Xe_1(n) + Xe_2(n)$$

متغیر $Xe(n)$ خروجی دو زیرسیستم قطعه‌بندی در شکل ۱ است. آنچه در فاز نهایی قطعه‌بندی انجام می‌شود این است که خروجی هر دو زیرسیستم را ترکیب می‌نماید و قایع نهایی را پس از اصلاح زمان‌های شروع و پایان استخراج می‌کند. در اصلاح زمانی، فریمی که زمان شروع زودتری دارد زمان شروع اتفاق صوتی و فریمی که زمان پایان دیرتری دارد زمان خاتمه واقعه را مشخص می‌کند.

۴-۱-عملیات قطعه‌بندی

جهت قطعه‌بندی، برای هر کدام از دو زیرسیستم یک مقدار آستانه عمومی ثابت و جداگانه تعریف شده است. شبه کدهای (۶) و (۷) نقش هر یک از پارامترهای آلفا و بتا را در انتخاب فریم در زیرسیستم‌ها نشان می‌دهند.

$$(6) \quad IF (ZC_k >= (\text{norm_zc} + \alpha) . OR. HZCRR_k >= 0.50) \\ select Frame k as a candidate frame being in an event. \\ Where (\text{norm_zc} and \alpha have a predefined values).$$

$$(7) \quad IF (STE_k >= (\text{norm_En} * \beta) . OR. LSTER_k <= 0.50) \\ select Frame k as a candidate frame being in an event \\ Where (\text{norm_En} and \beta have a predefined values).$$

در شبه کدها، k اندیس فریم است و norm_{zc} و norm_{en} به ترتیب متعلق به ویژگی عبور از صفر و ویژگی انرژی هستند. در زیرسیستم اول به دلیل وجود نویز در فریم‌ها و مشابهت صدای خاصی مثل $drawer, phone, printer$ به فریم‌های نویز، از ویژگی میزان عبور از صفر به همراه تغییرات عبور از صفر استفاده شده است. تمام فریم‌هایی که مقدار عبور از صفر آن‌ها بالاتر از α است و یا اینکه میزان تغییرات عبور از صفر در طی ۱ ثانیه بیش از 0.5 است، به عنوان کاندید در یک واقعه صوتی انتخاب می‌شوند. نقش پارامتر α کلیدی است به طوری که با تغییر α عملای می‌توان نقش ویژگی عبور از صفر را کم یا زیاد کرد و در مورد صدای متفاوت می‌توان مقدار مختلفی را برای α بدست آورد.

۴-۳-ویژگی انرژی فریم‌های صوتی

طبق آزمایش‌ها مشخص شد که این ویژگی در شرایط محیط نویزی چندان ممیز نیست اما پس از حذف نویز و استفاده از روش‌های پیش‌پردازش مشاهده شد که انرژی فریم‌ها می‌تواند اطلاعات مفیدی در مورد صدای خاص تولید کند. صدای کوبه‌ای مانند door - knock, door - slam, drawer, pendrop و یا صدای دماغی و صامت در گفتار دارای میزان انرژی بالای بودند. جهت نمونه در ۱۰ سیگنال آزمایش تعداد خطای شناسایی فریم‌های صدای قبل از پیش‌پردازش بطور متوسط در حدود $FPR = 0.58$ بود. اما پس از انجام مراحل حذف نویز در همان نمونه‌ها این میزان به $FPR = 0.46$ کاهش یافت که بیانگر قابلیت شناسایی صدای توسعه این ویژگی است.

۴-۴-ویژگی نسبت پایین انرژی کوتاه‌مدت

یکی از ویژگی‌های سیگنال در حوزه زمان تغییرات انرژی در فریم‌های مجاور به طول ۱ ثانیه است که آنرا نسبت پایین انرژی کوتاه‌مدت^۷ (LSTER) می‌نامند. این ویژگی طبق رابطه (۳) تعریف می‌شود.

$$(3) \quad LSTER = \frac{1}{2N} \sum_{n=0}^{N-1} [sgn(0.5avSTE - STE(n) + 1)]$$

متغیر n اندیس فریم است، $avSTE$ میانگین انرژی در فریم‌های مجاور به طول ۱ ثانیه است. در اینجا هر ۱ ثانیه شامل ۸ فریم 125 میلی‌ثانیه است. تعداد کل فریم‌ها N است. در اینجا این ویژگی برای شناسایی صدای ای همچون door - knock, drawer, pen - drop استفاده شده است. مقادیر انرژی فریم‌ها در این صدای علاوه بر بالا بودن، تغییرهای درونی زیادی نیز دارند. این تغییرها سبب می‌شود نسبت فریم‌های دارای انرژی کمتر از متوسط زیاد باشد و به همین دلیل صدای ای که مرتب‌آن‌ها کم و زیاد می‌شود مقدار این ویژگی برای آن‌ها زیاد است و تاحدزیادی قابل شناسایی هستند.

۴-پیاده‌سازی مدل بر حسب الگوریتم پیشنهادی


در فاز قطعه‌بندی بردارهای ویژگی به دو گروه تقسیم می‌شوند. گروه نخست شامل ویژگی‌های $(Zc, HZCCR)$ (عبور از صفر و تغییرات آن). گروه دوم ویژگی‌های $(STE, LSTER)$ (انرژی و تغییرات آن) است. زیرسیستم اول از ویژگی‌های گروه اول استفاده می‌کند. این ویژگی‌ها با انتخاب مناسب طول bin ها به اندازه 5 میلی‌ثانیه امکان شناسایی نقاط خیزش را در صدای مختلفی در سیگنال میسر می‌سازد. نقاط خیزش را در صدای مختلفی در سیگنال میسر می‌سازد. قطعه‌بندی در این زیرسیستم دارای پارامتر α است که امکان یک تصمیم سخت یا تصمیم نرم قابل انعطاف را برای انتخاب نقاط کاندید خیزش مهیا می‌سازد. پارامتر α در اینجا عدد صحیح است که هر چه آلفا بزرگتر باشد، میزان دقت کشف واقعه بیشتر است.

زیرسیستم دوم از ویژگی‌های گروه دوم دوم استفاده می‌کند. طول فریم در اینجا 125 میلی‌ثانیه تعیین شده است. این ویژگی‌ها همراه با پارامتر β که عدد اعشاری است، انتخاب نقاط خیزش با انعطاف یا سخت‌گیرانه جهت قطعه‌بندی سیگنال را مهیا می‌سازند. نقاط کاندید


پایداری مجدد، نقطه افول و عبور از صدای محیطی فرض می‌شود. پارامتر β می‌تواند میزان فریم‌هایی که در صدای اکتشافی کاندید می‌شوند را کم یا زیاد کند به طوری که با زیاد شدن β انتخاب سخت‌تر می‌شود.

فاز نهایی ترکیب نتایج دو زیرسیستم رده‌بندی است. در مرحله ترکیب هر گاه واقعه‌ای توسط یکی از زیرسیستم‌ها یا هر دو زیرسیستم کشف شده باشد در لیست نهایی وقایع کشف شده آورده می‌شود.

در زیرسیستم دوم از ویژگی انرژی و تغییرات یک ثانیه‌ای آن به صورت شناسایی نقاط خیزش و افول استفاده شده است. فریمهایی که پس از یک دوره پایداری در انرژی سیگنال به یکباره حداقل به اندازه β افزایش انرژی دارند، به عنوان نقاط خیزش صدای محیطی شناسایی می‌شوند و نقاطی که این حداقل انرژی را پس از خیزش اولیه حفظ کنند، در محدوده صدا در نظر گرفته می‌شوند. پس از سپری شدن نقطه خیزش و نوسان‌های آن مجدد انرژی سیگنال به حالت پایدار و با تغییرات کمتر از β می‌رسد که این نقطه شروع



شکل ۵: نمودار بررسی قابلیت ویژگی عبور از صفر. محور افقی اندیس فریم‌ها و محور عمودی مقدار این ویژگی در فریم را نشان می‌دهد. مقدار این ویژگی در فریم نشان می‌دهد که نقاط شروع و پایان برخی از وقایع قابل شناسایی هستند.




$$\text{Centroid}(m) = \frac{\sum_{k=1}^{N-1} (k+1).|X_k(m)|}{\sum_{k=1}^{N-1} |X_k(m)|} \quad (10)$$

$$\text{Flux}(m) = \sum_{k=1}^{N-1} (|X_k(m)| - |X_k(m-1)|) \quad (11)$$

$$\text{Entropy}(m) = -\sum_{k=1}^{N-1} |X_k(m)| \cdot \log_2 (|X_k(m)|) \quad (12)$$

پس از فریم‌بندی و استخراج ویژگی‌ها از واقعی کشف شده تمام بردارهای ویژگی استخراجی از فریم‌ها نرمال‌سازی شده و سپس از الگوریتم k-nearest neighbors algorithm (k-NN) برای رده‌بندی همانند شکل ۷ برای رده‌بندی هر فریم استفاده می‌شود. پس از رده‌بندی فریم‌های هر سگمنت، یک تصمیم‌گیری نهایی بر پایه رای گیری و کسب بیشترین رای برای تعیین کلاس مربوط به واقعه‌صوتی انجام می‌شود. برای تخمین دقیق‌تر مقدار K آزمایش‌های متعدد بر روی مقادیر ۱۱، ۹، ۷، ۵، ۳، ۱ K=۷ بهترین نتیجه را داشت. جهت فاصله‌بایی ابتدا روش‌های اقلیدسی، فاصله‌کسینوسی، مینکوواسکی و چای‌اسکوییر بررسی و محسوبه شدند که نتایج حاصل از روش چای‌اسکوییر بهتر از روش‌های دیگر بود و انتخاب گردید.



شکل ۷: پس از قطعه‌بندی از الگوریتم K-NN با مقدار K=۷ برای رده‌بندی استفاده شده است.

۵- اجرای مدل و نتایج

در این مرحله مدل پیشنهادی در قالب الگوریتم شکل ۱ بصورت مکرر آزمایش شد و نتایج جمع‌آوری گردیدند. در آزمایش‌ها از پایگاه داده تمیه شده در انجمن بین‌المللی تخصصی پردازش سیگنال صوت^۸ استفاده شده است. این داده‌ها مرتبط با صحنه‌های شنیداری مختلف از جمله صدای موجود در اتاق کار یا جلسه است که حاوی ۱۶ نوع اتفاق صوتی مطابق جدول ۱ است. طول زمانی هر یک از رکوردهای مورد پردازش ۳ دقیقه و به طور متوسط هر رکورد شامل ۳۵ اتفاق صوتی می‌باشد. رکوردها در شرایط وجود نویز محیطی متغیر ضبط شده‌اند، لذا صدای دارای شرایط محیط زنده هستند و صدای مصنوعی^۹ محسوب نمی‌شوند. در مجموع از تعداد ۶۰ رکورد مختلف استفاده شد و جهت اجرای سریع‌تر آزمایش‌ها هر بار یک گروه ۱۰ رکوردهای برای آزمایش انتخاب و نتایج آن گروه یادداشت شد. انتخاب رکوردهای هر گروه شامل انتخاب ۱۰ رکورد به صورت تصادفی و غیرتکراری از بین ۶۰ رکورد موجود می‌باشد. لذا در آزمایش‌ها نتایج گروه‌های ۱ تا ۶ را جداگانه بدست‌آورده و نهایتاً میانگین گروه‌ها

۴-۲- عملیات ردیابی

ابتدا تعداد ۶۱ ویژگی از فریم‌های واقعی اکتشافی استخراج می‌شود. همین ویژگی‌ها در مورد داده‌های آموزشی برای هر واقعه صوتی نیز بصورت مجزا استخراج می‌شود و از آن‌ها بردارهای نمونه هر صدا ایجاد می‌گردد. ویژگی‌های استفاده شده در این مرحله و تعداد هر کدام عبارتند از: عبور از صفر (۱)، انرژی کوتاه‌مدت (۱)، مركّز ثقل فرکانسی (۱)، بهنای باند فرکانسی (۱)، لگاریتم انرژی بانک فیلترهای فرکانسی مل (۱۶)، ضرایب دلتا و دلتای دوم بانک فیلترهای مل (۳۲)، انرژی زیرباندهای چهارگانه (۴)، اسپکتروال فلکس هر زیرباند (۴) و انتروپی یا پیچیدگی درون فریم (۱).

در انتخاب ویژگی‌ها دو جهت کاملاً مجزا و مکمل سیگنال یعنی حوزه ادراکی و حوزه تبدیل طیف لحاظ گردید. این ویژگی‌ها پیش از این در کارهای پژوهشی متعدد استفاده شده است و مستقل هستند [۲۶-۲۹]. تعداد ۱۶ ویژگی تبدیل طیف که از لگاریتم بانک‌های فیلتر مل گرفته شده است، بر مبنای درک فرکانس توسعه سیستم شناوری انسان است. مشتقات اول و دوم زمانی آن‌ها تکمیل‌کننده اطلاعات دینامیکی در گذر زمان هستند که در کنار ویژگی‌های قبلی مکمل فرض می‌شوند. به علاوه ویژگی‌های دیگری همچون میزان عبور از صفر یا انرژی نیز توصیف کننده رفتار زمانی و مکمل حوزه فرکانس هستند. دلیل انتخاب ما علاوه بر مکمل بودن این ویژگی‌ها و مستقل از هم بودن آن‌ها، وجود صدای متنوع از جمله گفتار، خنده، سرفه ازیک سو و از سوی دیگر صدای تلفن، چاپگر، کلید، آلام و غیره است. گروه اول وکال یا گلوتال (حنجره‌ای) است و گروه دوم (یعنی صدای محیطی) بیشتر بدون نظم و شکل خاص است که باید از نظر زمانی و از نظر فرکانسی مدل شوند.

طول فریم‌ها ۲۵ میلی‌ثانیه و میزان هم‌پوشانی آن‌ها ۶۰ درصد انتخاب شد. نمایش فرکانسی هر فریم m، $X_k(m)$ نامیده می‌شود. با استفاده از تبدیل گسسته فوریه و اعمال پنجره هنینگ (n) طبق رابطه‌های (۸)، (۹) انجام شده است.

$$X_k(m) = \sum_{n=-\infty}^{\infty} x(n).w_b(n-m).e^{-j2\pi kn/N}, \quad 0 \leq k \leq N-1 \quad (8)$$

$$w_b(n) = \begin{cases} 0.5 - 0.5 \cos(\frac{\pi n}{b}), & 0 \leq n \leq b \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

در رابطه‌های (۸)، (۹) متغیرهای N, n, k, b به ترتیب از چپ به راست طول DFT، اندیس حوزه‌زمان، اندیس حوزه فرکانس و طول پنجره هنینگ می‌باشند. محاسبه مركّز ثقل فرکانسی، اسپکتروال فلکس و انتروپی در رابطه‌های (۱۰) تا (۱۲) بر اساس مراجع [۲۶، ۲۷] آورده شده است.

و در اجراهای دیگر این نتیجه معکوس است. نتایج این آزمایش بهوضوح موثر بودن هر دو پارامتر آلفا و بتا را مستقل از هم تایید می‌کند. در ادامه آزمایش‌هایی جهت تعیین بهترین آلفا و بتا برای حداکثر کردن معیارهای سه‌گانه انجام شد. نتایج حداکثرسازی میزان دققت در جدول ۳ آمده است. ستون‌های α و β مقادیری را نشان می‌دهند که به ازای آن‌ها میزان دققت در رکوردهای ورودی حداکثر است. به طور میانگین، برای پارامترهای $\alpha = 5$ و $\beta = 1/41$ حداکثر دققت در $2/2$ درصد است.

جدول ۳: حداکثرسازی میزان دققت بر حسب انتخاب مقدار بهینه برای پارامترهای α و β در سیستم

Precision: max	Recall	F1(RB)	α	β	Group
۰/۶۷۱	۰/۴۰۴	۰/۵۰۴	۵	۱/۵۳	۱
۰/۷۰۲	۰/۴۵۵	۰/۵۵۲	۴	۱/۴۰	۲
۰/۵۸۶	۰/۳۶۳	۰/۴۴۸	۵	۱/۲۴	۳
۰/۷۱۶	۰/۳۷۹	۰/۴۹۶	۶	۱/۴۴	۴
۰/۶۰۸	۰/۳۳۴	۰/۴۳۱	۳	۱/۴۸	۵
۰/۶۸۹	۰/۴۳۰	۰/۵۳۰	۷	۱/۳۵	۶
۰/۶۶۲	۰/۳۹۴	۰/۴۹۴	۵	۱/۴۱	میانگین

نتایج حداکثرسازی تعداد وقایع کشفشده (میزان فراخوانی) در جدول ۴ آمده است. مقدار بهینه پارامترها $\alpha = 5$ و $\beta = 1/۱۶$ است. اجرا با مقادیر میانگین پارامترها از جدول ۴ میزان فراخوانی را حداکثر به $58/4$ درصد رسانید.

جدول ۴: مقدار بهینه پارامترهای α و β در حداکثرسازی میزان فراخوانی

Precision	Recall: max	F1(RB)	α	β	Group
۰/۵۶۳	۰/۶۴۴	۰/۶۰۱	۶	۱/۱۳	۱
۰/۵۳۶	۰/۵۹۷	۰/۵۶۵	۵	۱/۱۵	۲
۰/۵۱۰	۰/۵۵۱	۰/۵۳۰	۷	۱/۱۲	۳
۰/۶۲۸	۰/۶۰۴	۰/۶۱۶	۶	۱/۲۲	۴
۰/۴۷۲	۰/۵۰۵	۰/۴۸۸	۵	۱/۱۳	۵
۰/۵۵۰	۰/۵۷۳	۰/۵۶۱	۳	۱/۲۰	۶
۰/۵۴۳	۰/۵۷۹	۰/۵۶۰	۵	۱/۱۶	میانگین

در جدول ۵ مقادیر معیارها بر اساس پارامترهای بهینه α و β به صورت مقایسه‌ای آورده شده است.

جدول ۵: مقایسه مقادیر معیارها بر اساس پارامترهای بهینه

Precision	Recall	F1(RB)	α	β
۰/۶۶۲	۰/۴۰۳	۰/۵۰۱	۵	۱/۴۱
۰/۵۴۴	۰/۵۸۴	۰/۵۶۳	۵	۱/۱۶
۰/۶۱۲	۰/۵۳۹	۰/۵۷۳	۶	۱/۲۱
۰/۶۰۶	۰/۵۰۹	۰/۵۴۶	۵	۱/۲۶

جهت مقایسه نتایج با کارهای مشابه ابتدا نتایج معیار F1 که در جداول ۱-۵ بر حسب کلیپ (یا رکورد) و میانگین بین رکوردها محاسبه شده و (RB) record-based می‌باشد به صورت یکپارچه براساس فریم event-based (FB) و سپس براساس واقعه (EB) Frame-based نتایج پردازش فریمی و بر حسب واقعه در جدول ۶ محاسبه می‌شود.

به عنوان نتیجه کلی آزمایش ۶۰ رکورد در نظر گرفته شد. الگوریتم با معیارهای دقت، میزان فراخوانی و میانگین هارمونیک وزنی^۱ (معیار کارایی) مورد سنجش قرار گرفته است. این معیارها با توجه به نیاز الگوریتم در رابطه‌های (۱۳) تا (۱۵) معرفی شده‌اند.

Precision=

$$\text{تعداد کل وقایع صوتی که الگوریتم بدرسی آنها را شناسایی کرده است}$$

تعداد کل وقایعی که الگوریتم شناسایی کرده است

(۱۳)

Recall=

$$\text{تعداد کل وقایع صوتی که الگوریتم بدرسی آنها را شناسایی کرده است}$$

تعداد واقعی وقایع در رکورد صوتی ورودی

$$\frac{2 * (\text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (15)$$

در تمام آزمایش‌های انجام شده بهترین نتایج مربوط به رکوردها در ارزیابی در نظر گرفته شده‌اند.

در اولین آزمایش میزان فراخوانی عملکرد الگوریتم بدون در نظر گرفتن پارامترهای آلفا و بتا که معادل $\alpha = ۰$ و $\beta = ۱/۰$ است بررسی گردید که نتایج آن در جدول ۲ ارائه شده است. میانگین میزان دققت ۴۴ درصد و میانگین فراخوانی ۶/۴۷ درصد و میزان کارایی میانگین در بین رکوردهای آزمایش شده که آنرا F1 بر اساس کلیپ یا رکورد (RB) F1(RB) نامیده و با record-based در جدول ۲ نشان می‌دهیم درصد است. این شرایط اولیه الگوریتم است و می‌توان با دخالت دادن پارامترها عملکرد سیستم را بهبود داد. در آزمایش‌های بعدی با استفاده از پارامترهای مذکور، عملکرد سیستم به طور محسوسی افزایش داشته است و این بیانگر دینامیک عمل کردن سیستم با تغییر پارامترها است. همچنین می‌توان گفت که بهبود بیشتر میزان دققت، بیانگر تاثیر بیشتر و مستقیم پارامترها بر کم شدن خطای کشف است.

جدول ۲: عملکرد الگوریتم بدون اعمال پارامترهای α و β (هر Group)

شامل ۱۰ رکورد از بین ۶۰ رکورد آزمایش و بدون تکرار است

Precision	Recall	F1(RB)	Group
۰/۴۲۲	۰/۵۰۱	۰/۴۵۸	۱
۰/۴۳۸	۰/۵۱۴	۰/۴۷۳	۲
۰/۴۹۵	۰/۵۴۳	۰/۵۱۸	۳
۰/۴۴۳	۰/۴۷۱	۰/۴۵۷	۴
۰/۴۲۵	۰/۳۹۸	۰/۴۱۱	۵
۰/۴۷۳	۰/۴۲۶	۰/۴۴۸	۶
۰/۴۴۹	۰/۴۷۶	۰/۴۶۱	میانگین

جهت بررسی تاثیر پارامترها، ابتدا ۱۰ رکوردی به طور تصادفی انتخاب شد. با هر گروه سه اجرا به صورت عدم استفاده از پارامترها، فقط پارامتر آلفا و فقط پارامتر بتا انجام و میانگین هر اجرا گرفته شد. سپس درصد معیار F1 از میانگین محاسبه و نتایج در شکل ۸ آورده شد. همانطور که مشخص است میزان شناسایی در اجراهای دوم و سوم در تمام گروه‌ها بالاتر از اجرای اول در همان گروه است. در برخی اجراهای از جمله ۲، ۴، ۷، ۸ تاثیر آلفا به تنها یکی بیشتر از بتا بوده

تنظیم سیستم بین دقت بالاتر یا فراخوانی بالاتر را ممکن می‌سازد. نتایج دیگر تحقیق این است که استفاده از دو زیرسیستم قطعه‌بندی و کشف وقایع و ترکیب نتایج سبب استفاده هر چه بهتر از ویژگی‌ها شده و امکان بالارفتن قابلیت جداسازی ویژگی‌ها و کشف بیشتر وقایع را میسر می‌سازد. به علاوه در آزمایش‌ها مشخص شد که تفکیک ویژگی‌ها به دو گروه، شناسایی صدای خاص توسط ویژگی خاص را عملی می‌سازد. نتایج بدست آمده تائیر قابل ملاحظه پارامترها در مقایسه با حالت اولیه مدل را به خوبی نشان می‌دهد. در آزمایش‌ها مقادیر پارامترها برای حداقل نمودن معیارهای دقت، فراخوانی و کارایی محاسبه و نتایج ارائه شد. مشخص شد، با تعیین مقادیر پارامترها معیارهای مورد نظر تا حد امکان بهینه و حداقل می‌شوند. مشخص شد، ترکیب نتایج دو زیرسیستم و استفاده از روش‌های یکپارچه‌سازی و اصلاح نهایی محدوده وقایع در میزان دقت نهایی اثر دارد.

۷- پیشنهادها جهت کارهای آینده

یکی از معضلات اصلی وجود نویز بالا و متغیر در رکوردهای صوتی است. روش‌های بهتری برای مقاوم نمودن الگوریتم در برابر نویز پیشنهاد می‌شود. بعضی از صدای‌های محیطی شبیه نویز زمینه هستند لذا معرفی ویژگی‌های زمانی که صدای‌های نویز-مانند را دقیق‌تر کشف نماید پیشنهاد می‌شود. جهت مقابله با نویز در داده‌ها، مدل‌سازی نویز محیط به صورت یک سطح مجزا پیشنهاد می‌شود. استفاده از ویژگی‌های حوزه‌فرکانس و ادرکی در یک زیرسیستم و ویژگی‌های حوزه‌زمان در زیرسیستم دیگر در قطعه‌بندی پیشنهاد می‌شود.

آورده شده است. بهبودی نتایج در سطح فرمی (FB) بدليل تشخیص بهتر اطلاعات در فرم نسبت به سطح بالاتر واقعه (EB) است و طبیعتاً شناسایی یک واقعه در حد چندانیه که متشکل از تعداد زیادی فرم است کار مشکل‌تر و همراه با خطای بیشتر است. تفاوت نتایج سطح واقعه با سطح رکوردهای کلی و قائم در بین رکوردها و همچنین چگالی متفاوت برای هر واقعه در رکوردها و میانگین‌گیری صورت گرفته در بین رکوردهای هر گروه است که نهایتاً لحظه نمودن نتایج در رکوردها به طور مستقل و میانگین بین آن‌ها، سبب نتایج ضعیفتر RB نسبت به EB است. اما آنچه در نتایج مورد قیاس قرار می‌گیرد میزان معیار F1 بر اساس EB، F1 (EB)، EB، FB، F1 (FB) بر روی


جدول ۶: مقادیر معیار ارزیابی F1 بر اساس واقعه (EB) و فرم (FB) بر روی مجموعه داده‌های آزمایش.

Maximization	F1(EB)	F1(FB)
precision	.۰/۷۰۱	.۰/۷۷۳
recall	.۰/۷۵۸	.۰/۸۳۷
F1-measure	.۰/۷۲۸	.۰/۸۰۶


مقایسه نتایج با پژوهش‌های مرتبط در شکل ۹ آمده است. نتایج مشخص می‌کند که مدل پیشنهادی بیش از ۱۰٪ بهبودی داشته است و دلیل آن مدل‌سازی بهتر نسبت به قبل است.

۶- نتیجه‌گیری

در این پژوهش یک روش جدید مدل‌سازی تطبیق‌پذیر با دو پارامتر جهت کشف وقایع صوتی در سیگنال‌های محیطی ارائه شد. مدل از دو پارامتر کلیدی α و β استفاده می‌کند که تاحدزیادی سبب بهبود عملکرد اولیه سیستم می‌گردد و همچنین انعطاف‌پذیری و قابلیت



شکل ۸: بررسی عملکرد پارامترهای آلفا و بتا به صورت جداگانه در شناسایی وقایع. اجرای بدون پارامترها کمترین میزان شناسایی وقایع را دارد. با اعمال هر یک از پارامترها دیده می‌شود که نرخ شناسایی بطور قابل ملاحظه‌ای افزایش دارد. در بعضی موارد پارامتر آلفا و در بعضی دیگر پارامتر بتا تاثیر بیشتری در افزایش نرخ شناسایی دارد.



شکل ۹: درصد شناسایی وقایع بر حسب معیار F1 در سیستم پیشنهادی (proposed) در دو مقیاس فریم (FB) و واقعه (EB). مجموعه داده‌های استفاده شده مربوط به AED (2013) در شاخه IEEE AASP است که شامل ۱۶ نوع صدای محیطی اداری می‌باشد.

- events ” *IEEE Transactions on Multimedia* vol. 17 no. 10 pp. 1733 – 1746, 2015.
- [8] R. Togneri and D. Pulella, “An overview of speaker identification: Accuracy and robustness issues,” *IEEE Circuits and Systems Magazine*, vol. 11, no. 2, pp. 23–61, 2011.
 - [9] S. Pancoast and M. Akbacak, “Bag-of-audio-words approach for multimedia event classification,” in *Interspeech*, Portland, Oregon, USA, 2012.
 - [10] A. Plinge, R. Grzeszick, and G. Fink, “A Bag-of-Features approach to acoustic event detection,” in *IEEE (ICASSP)*, Florence, Italy, May 2014.
 - [11] T. Heittola, A. Mesaros, T. Virtanen, and A. Eronen, “Sound event detection in multisource environments using source separation,” in *Proc. CHiME*, Florence, Italy, pp. 36–40, 2011.
 - [12] R. Hennequin, R. Badeau and B. David, “NMF with Time-Frequency Activations to Model Nonstationary Audio Events,” *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 19, no. 4, pp. 744-753, 2011.
 - [13] T. Komatsu, Y. Senda, and R. Kondo, “Acoustic event detection based on non-negative matrix factorization with mixtures of local dictionaries and activation aggregation,” *IEEE (ICASSP)*, shanghai, china, pp. 2259–2263, 2016.
 - [14] X. Lu, Y. Tsao, S. Matsuda and C. Hori, “Sparse representation based on a bag of spectral exemplars for acoustic event detection,” *IEEE (ICASSP)*, Florence, Italy, pp. 6255-6259, 2014.
 - [15] IEEE DCASE 2016 Challenge, <http://www.cs.tut.fi/sgn/arg/dcase2016/>, 2016.
 - [16] I. Choi, K. Kwon, S. Hyun Bae, and N. Soo Kim, “DNN-based sound event detection with exemplar-based approach for noise

مراجع

- [1] F. Aurino, M. Folla, F. Gargiulo, V. Moscato, A. Picariello, and C. Sansone, “One-class SVM-based approach for detecting anomalous audio events,” *International Conference on Intelligent Networking and Collaborative Systems*, Salerno, Italy, pp. 145-151, 2014.
- [2] V. Carletti, P. Foggia, G. Percannella, A. Saggese, N. Strisciuglio, and M. Vento, “Audio surveillance using a bag of aural words classifier,” *Advanced Video and Signal Based Surveillance, 10th IEEE International Conference on*, Krakow, Poland, pp. 81-86, 2013.
- [3] R. Maher, “Acoustical modeling of gunshots including directional information and reflections,” in *131st Audio Engineering Society Convention*, New York, NY, 2011.
- [4] R. Cai, L. Lu, and A. Hanjalic, “Co-clustering for Auditory Scene Categorization,” in *IEEE Transactions on Multimedia*, vol. 10, no. 4, pp. 170-177, 2008.
- [5] Y. Ohishi, D. Mochihashi, T. Matsui, M. Nakano, H. Kameoka, T. Izumitani, and K. Kashino, “Bayesian semi-supervised audio event transcription based on markov indian buffet process,” *IEEE (ICASSP)*, Vancouver, Canada, pp. 3163–3167, 2013.
- [6] E. Benetos, G. Lafay, M. Lagrange, and M. Plumbley, “Detection of overlapping acoustic events using a temporally constrained probabilistic model,” *IEEE (ICASSP)*, shanghai, china, pp. 6450–6454, 2016.
- [7] D. Stowell, D. Giannoulis, E. Benetos, M. Lagrange, and M. D. Plumbley, “Detection and classification of acoustic scenes and

- [27] D. Li, J. Tam, and D. Toub, "Auditory scene classification using machine learning techniques," *technical report*, 2013.
- [28] X. Zhou, X. Zhuang, M. Liu, H. Tang, M. Hasegawa-Johnson, and T. Huang, "HMM-based acoustic event detection with AdaBoost feature selection," in *Multimodal Technologies for Perception of Humans*, Springer-verlag Berlin, Heidelberg, pp. 345-353, 2008.
- [29] A. Mesaros, T. Heittola, A. Eronen, and T. Virtanen, "Acoustic event detection in real life recordings," in *Proceedings of the 18th European Signal Processing Conference, Eusipco 2010*, Aalborg, Denmark, pp. 1267-1271, August 2010.
- [30] W. Nogueira, G. Roma, and P. Herrera, "Automatic event classification using front end single channel noise reduction, MFCC features and a support vector machine classifier," *IEEE Workshop Appl. Signal Process. Audio Acoust. (WASPAA)*, New Paltz, NY, USA, Oct. 2013.
- [31] M. E. Niessen, T. L. M. V. Kasteren, and A. Merentitis, "Hierarchical modeling using automated sub-clustering for sound event recognition," in *Proc. IEEE Workshop Appl. Signal Process. Audio Acoust. (WASPAA)*, New Paltz, NY, USA, Oct. 2013, pp. 1-4.
- [32] J. F. Gemmeke, L. Vugene, P. Karsmakers, B. Vanrumste, and H. V. hamme, "An exemplar-based NMF approach to audio event detection," *IEEE Workshop Appl. Signal Process. Audio Acoust. (WASPAA)*, New Paltz, NY, USA, Oct. 2013.
- [33] L. Vugena, B. V. D. Broeck, P. Karsmakers, J. F. Gemmeke, B. Vanrumste, and H. V. hamme, "An MFCC-GMM approach for event detection and classification," *IEEE Workshop Appl. Signal Process. Audio Acoust. (WASPAA)*, New Paltz, NY, USA, Oct. 2013.
- [34] J. Schröder, B. Cauchi, M. R. Schädler, N. Moritz, K. Adiloglu, J. Anemüller, S. Doclo, B. Kollmeier, and S. Goetze, "Acoustic event detection using signal enhancement and spectro-temporal feature extraction," *IEEE Workshop Appl. Signal Process. Audio Acoust. (WASPAA)*, New Paltz, NY, USA, Oct. 2013.
- [35] A. Dimant, T. Heittola, and T. Virtanen, "Sound event detection for office live and office synthetic AASP challenge," *IEEE Workshop Appl. Signal Process. Audio Acoust. (WASPAA)*, New Paltz, NY, USA, Oct. 2013.
- [36] J. Schroder, S. Goetze, and J. Anemuller, "Spectro-Temporal Gabor Filterbank Features for Acoustic Event Detection," in *IEEE/ACM Transactions on Audio, and Language Processing*, vol. 23, no. 12, pp. 2198-2208, 2015.
- [17] reduction," in *Proc. IEEE (DCASE)*, Budapest, Hungary, September 2016.
- [18] T. Hayashi, S. Watanabe, T. Toda, T. Hori, J. Le Roux, and K. Takeda, "Bidirectional LSTM-HMM hybrid system for polyphonic sound event detection," in *Proc. IEEE (DCASE)*, Budapest, Hungary, September 2016.
- [19] J. Kurby, R. Grzesick, A. Plinge, and G. A. Fink, "Bag-of-features acoustic event detection for sensor networks," in *Proc. IEEE (DCASE)*, Budapest, Hungary, September 2016.
- [20] M. Zohrer, and F. Pernkopf, "Gated recurrent networks applied to acoustic scene classification and acoustic event detection," in *Proc. IEEE (DCASE)*, Budapest, Hungary, September 2016.
- [21] X. Zhuang, X. Zhou, M. Hasegawa-Johnson, and T. S. Huang, "Real-world acoustic event detection," *Pattern recognition Letters*, vol. 31, no. 12, pp. 1543-1551, 2010.
- [22] E. Miquel, F. Masakiyo, S. Daisuke, O. Nobutaka, and S. Shigeki, "A tandem connectionist model using combination of multi-scale spectro-temporal features for acoustic event detection," in *Proc. IEEE (ICASSP)*, Kyoto, Japan, pp. 4293-4296, 2012.
- [23] مجتبی حاجی آبادی، عباس ابراهیمی مقدم و حسین خوشبین، «حذف نویز مبتنی بر یک الگوریتم وقی نوین»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۶، شماره ۳، صفحات ۱۴۷-۱۳۹۵، ۱۳۹۵.
- [24] مسعود گراآنچی زاده و ساناز قائمی سردروندی، «بهبود کیفیت گفتار مبتنی بر بهینه‌سازی ازدحام ذرات با استفاده از ویژگی‌های ماسک‌گذاری سیستم شنواری انسان»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۶، شماره ۳، صفحات ۲۹۷-۲۸۷، ۱۳۹۵.
- [25] T. Fawcett, "ROC Graphs: Notes and Practical Considerations for Researchers," *Pattern Recognition Letters*, vol. 27, no. 8, pp. 882-891, 2004.
- [26] J. T. Geiger, B. Schuller, and G. Rigoll, "Recognizing acoustic scenes with large-scale audio feature extraction and SVM," *TUM, technical report*, 2013.

زیرنویس‌ها

¹ - Boosting

² - Mel-frequency Cepstral Coefficients (MFCC)

³ - Log frequency filter bank

⁴ - Leveraging statistical models

⁵ - Tandem connectionist model

⁶ - Receiver Operating Characteristic (ROC)

⁷ - Low short-Time Energy Ratio (LSTER)

⁸ - IEEE Audio and Acoustic Signal Processing (AASP)

⁹ - Synthesis Sounds

¹⁰ - F1-measure