

ارائه الگوریتم نقاط با حداقل اطلاعات MIP

برای تشخیص ابتدا و انتهای دستورات گفتاری

کامبیز بدیع

دانشیار

مرکز تحقیقات مخابرات ایران

ابوالقاسم صیادیان

دانشیار

دانشکده برق، دانشگاه صنعتی امیرکبیر

نصرالله... مقدم

استادیار

دانشکده فنی و مهندسی، دانشگاه تربیت مدرس

محمد معین

استادیار

مرکز تحقیقات مخابرات ایران

چکیده

آشکارسازی کلمات و دستورات گفتاری در هنگام ضبط و بازشناسی در حضور انواع وقایع اکوستیکی غیر گفتاری (پف، کلیک، ته سرفه، بازدم صدا،...) و همچنین نویزهای زمینه تداوم دار یا غیر تداوم دار را VAD یا SBED می‌گویند. در یک تحقیق گسترده نشان داده شده است که حدوداً پنجاه درصد خطاهای یک سیستم بازشناسی گفتار، ناشی از خطای آشکارسازی دقیق مرز ابتدا و انتهای کلمات تلفظ شده (بویژه در حضور نویز) می‌باشد. در این تحقیق ضمن بررسی و پیاده سازی اغلب روشهای موفق، روشی ارائه نمودیم که ضمن استفاده از نقاط قوت روشهای رایج، دارای قابلیت پیاده سازی زمان زنده نیز می‌باشد. در این تحقیق ابتدا نقاطی از گفتار بنام نقاط MIP (نقطه با حداقل اطلاعات) شروع و پایان کلمه تشخیص داده می‌شود. آنگاه با استفاده از تخمین مشخصات مدل نویز زمینه (به کمک فیلتر غیر خطی مرتب کننده توان)، نقاط شروع و پایانی کلمه و همچنین، فریمهای سکوت بین سیلاهای درون کلمه‌ای نیز تشخیص داده می‌شوند. روش فوق همراه با دو روش موفق دیگر را در بازشناسی ۱۵۰۰ کلمه پر مصرف در کاربردهای IT و سرویسهای مخابراتی) مورد آزمون‌های مختلف قرار دادیم. در این آزمونها هم دقت روش‌ها و هم مقاومت آنها در مقابل انواع نویزهای زمینه (پریویویک و غیر پریویویک، ایستان و غیر ایستان، رتگی و غیر رتگی و ...) تحت SNR های (۰۰۰۰ و ۰۰۵۰ و ۰۰۱۵) را مورد بررسی قرار دادیم. در تمامی این آزمونها، روش MIP بعلت استفاده از حداقل اطلاعات قابل وصول در گفتار موفق‌تر بوده است.

کلمات کلیدی

بازشناسی گفتار، تشخیص ابتدا و انتهای گفتار، آشکارسازی فعالیت گفتار

Use of Maximum Information Point (MIP) for High Precision and Reliable Begin and Endpoint Detection of Speech Command

A. Sayadiyan
Associate Professor

K. Badi
Associate Professor

M. Moin
Assistant Professor

N. Moghadam
Assistant Professor

Abstract

Many speech detection methods have been proposed for the use in speech recognition systems. These methods can be broadly classified into three approaches according to their interaction with the pattern matching paradigm: (1) the explicit approach (2) the implicit approach (3) the hybrid approach. In this research we implement a new explicit method, which is reliable and very precise for real time applications. This new speech detection method (with name of maximum information point MIP) has been proposed and evaluated on a 1500 words discrete utterance speech command system. MIP method use of all low and high level information of speech signal and background noises. The evaluation results at (5 to 30 dB S/N ratio), and all variant of noise (white, color, periodic, stationary, non stationary, variable power level, ...), shows that the MIP method performance is better than the other classical methods.

Keywords

Speech Recognition, Speech Begin and End Point Detection, Voice Activity Detector

مقدمه

برای بازشناسی گفتار یا گوینده در دنیای واقعی، اغلب نیازمند هستیم که گفتار تلفظ شده در یک محیط آشنا به نویزهای محیطی مختلف را مورد پردازش و بازشناسی قرار دهیم. آشکارسازی گفتار در هنگام ضبط در حضور انواع وقایع اکوستیکی غیر گفتاری^۱ و نویزهای زمینه^۲ را SBED^۳ و یا ED^۴ و یا SAD^۵ و یا VAD^۶ می‌گویند. الگوریتمهای مرتبط با VAD نوعاً با محدودیت تأخیر کمتر از چند فریم(۲ تا ۳ فریم) مواجه هستند، در نتیجه معمولاً برای فشرده‌سازی و کدینگ گفتار استفاده می‌شوند. در الگوریتمهای مرتبط با SBED، تأخیری در حدود نیم تا حداکثر یک ثانیه قابل تحمل می‌باشد. سیستمهای پیشرفته بازشناسی گفتار یا گوینده، هم از روشهای SBED و هم از روشهای VAD استفاده مینمایند.

در یک تحقیق گسترده [۱] نشان داده شده است که حدود پنجاه درصد خطاهای یک سیستم بازشناسی گفتار، ناشی از خطای آشکارسازی دقیق مرز ابتدا و انتهای کلمات تلفظ شده می‌باشد. عدم دقت کافی در تشخیص فواصل سکوت سیالهای بین کلمه‌ای یا جمله‌ای نیز می‌تواند موجب کاهش دقت سیستمهای بازشناسی گفتار و گوینده گردد. بنابراین وظیفه روشهای SBED تشخیص دقیق و مطمئن ابتدا و انتهای گفتار تلفظ شده با فرض اینکه در فواصل ما قبل و ما بعد آن در هنگام ضبط نویزهای زمینه یا نویزهای اکوستیکی دیگری وجود دارد می‌باشد. همچنین وظیفه روشهای VAD، تشخیص فرمیهای گفتار از فریم‌های غیر گفتاری می‌باشد. نکته قابل توجه این است که، فرمیهای در فواصل ابتدا و انتهای یک تلفظ گفتاری می‌توانند، سکوت یا نویز زمینه باشند که تشخیص این مسئله به عهده بخش VAD می‌باشد.

وقایع اکوستیکی غیر گفتاری (با نویز) که سیگنال گفتار را در بر گرفته‌اند را می‌توان به دو گروه کلی؛ الف - نویزهای ضربه‌ای ب - نویزهای غیر ضربه‌ای یا تداوم دار^۷ تقسیم نمود. نویزهای ضربه‌ای توسط طول دوره آن نسبت به سیگنال گفتار قابل تشخیص می‌باشند[۲]. از جمله این نویزها، پف دهان، ته سرفه برای صاف کردن حنجره، کلیک و ضربه میکروفون و موس در هنگام جابجایی می‌باشد. نویزهای تداوم دار (غیر ضربه‌ای) معمولاً ما قبل و مابعد گفتار نیز موجودیت خود را حفظ مینمایند. روشهای عمدۀ برای تشخیص SBED و VAD نوعاً مبتنی بر فرض وجود نویزهای تداوم دار می‌باشند. نویزهای زمینه، نویزهای مربوطه به صدای همهمه، نویزهای مربوط به صدای پنکه، فن، صدای موتور خانه، صدای موتوری‌چال، صدای موتور جارو برقی، صدای کولر، صدای ماشین لباسشوئی، صدای موتور انواع ماشینها (در داخل یا خارج ماشین) و ... همگی جزء نویزهای تداوم دار محسوب می‌شوند. نویزها از نظر هموار بودن طیف به دو گروه؛ نویزهای سفید^۸ و نویزهای رنگی^۹ نیز دسته‌بندی می‌گردند. در نویزهای سفید، پوش طیف تقریباً هموار و یکنواخت می‌باشد. ولی نویزهای رنگی دارای قطب و صفرهایی در پوش طیف می‌باشند. نویزها از نظر ثابت بودن یا متغیر بودن مشخصه‌های آماری و طیفی به دو گروه کلی نویزهای ایستان^{۱۰} و غیر ایستان^{۱۱} نیز تقسیم‌بندی می‌گردند. تکنیکهای SBED و VAD برای نویزهای غیر ایستان معمولاً پیچیده‌تر از نویزهای ایستان می‌باشند. نویزهای تداوم دار از نظر تکراری بودن نیز به دو گروه نویزهای پریودیک و غیر پریودیک نیز تقسیم‌بندی می‌شوند.

یکی دیگر از مشخصه نویزها، ثابت بودن یا متغیر بودن سطح انرژی نویز در فواصل ماقبل و ما بعد گفتار می‌باشد. به نویزی که سطح انرژی آن در فواصل ماقبل و ما بعد تقریباً ثابت باشد نویز VLN^{۱۲} و در غیر اینصورت SBED و VAD برای نویزهای با سطح انرژی VLN معمولاً پیچیده‌تر از نویزهای با سطح انرژی تقریباً ثابت می‌باشد [۲]. در این تحقیق فرض برای این است که سطح نویز در فاصله تلفظ یک کلمه یا فرمان تقریباً ثابت بوده ولی در طول ضبط میتواند تغییر نماید. روش‌های SBED معمولاً به دو گروه کلی BM^{۱۵} و RTM^{۱۶} قابل تفکیک می‌باشند [۳]. در روش‌های پردازش دسته‌ای BM فرض بر این است که اطلاعات تمامی فریم‌های گفتار و مقدار مناسبی از فریم‌های سکوت ماقبل و مابعد در اختیار می‌باشد [۳]. این روشها معمولاً در تصدیق و تعیین هویت گوینده‌ها و سیستمهای شماره‌گیری صوتی، دستورات صوتی، و ... مورد استفاده قرار می‌گیرند. در این روشها، پس از ضبط مقدار مناسبی گفتار (همراه با سکوت ماقبل و مابعد) فرآیند ضبط قطع شده و سیستم به فرآیند پردازش و بازناسی می‌پردازد. یعنی فرآیند پردازش و بازناسی پس از خاتمه ضبط انجام می‌پذیرد. چون تمامی اطلاعات گفتار یکجا در اختیار می‌باشد، انتظار این است که روش‌های BM دارای دقت و عملکرد بالاتری نسبت به روش‌های RTM باشند.

در روش‌های زمان زنده RTM، نتیجه پاسخ SBED و بازناسی گفتار، سریعتر یا همزمان با ختم فرآیند ضبط یا تلفظ گفتار انجام می‌پذیرد. (با یک تأخیر ثابت و کم). منطقی است که روش‌های مورد استفاده در کاربردهای RTM می‌باشند از نظر محاسباتی سریعتر باشند. روش مورد نظر در این تحقیق جزء روش‌های RTM بوده اگرچه برای کاربردهای BM نیز قابل استفاده است. روش‌های تشخیص ابتدا و انتهای گفتار SBED از نظر وابستگی به نوع مدلسازی بازناسی گفتار نیز به سه دسته کلی؛ الف - روش‌های صریح^{۱۷} ب - روش‌های ضمنی^{۱۸} ج - روش‌های تلفیقی^{۱۹} تقسیم بندی می‌گردد [۴].

روش‌های صریح، به روش‌هایی گفته می‌شود که فرآیند SBED مستقل از نوع مدلسازی کلاس‌های اکوستیکی (واج یا کلمه) و مستقل از نوع مدلسازی زبان و لهجه گوینده انجام می‌پذیرد. روش‌های صریح، از نظر کاربردی دارای انعطاف‌پذیری بیشتر و از نظر پیاده‌سازی سریعتر می‌باشند. روش‌های ضمنی، به روش‌هایی گفته می‌شود که فرآیند SBED همراه و جزئی از فرآیند مدلسازی کلاس‌های اکوستیکی مورد توجه و استفاده می‌باشد. این روشها نوعاً به نوع مدلسازی کلاس‌های اکوستیکی و زبان و لهجه و نوع گوینده وابسته می‌باشند. مهمترین روش‌های ضمنی، روش‌های HMMA^{۲۰} و DTWA^{۲۱} [۴] [۵] می‌باشند. دقت این روشها نوعاً بالاتر از روش‌های صریح است. انعطاف‌پذیری این روشها پائین بوده و هزینه محاسباتی پیاده‌سازی آنها بسیار بالا می‌باشد. در روش‌های تلفیقی از تلفیق مناسب روش‌های صریح و ضمنی استفاده می‌شود. بدین گونه که توسط روش‌های صریح، تعدادی کاندید برای ابتدا و انتهای کلمه یا جمله گفتاری پیشنهاد نموده و سپس به کمک روش‌های ضمنی، ابتدا و انتهای اصلی گفتار را بادقت بالاتر تعیین مینمایند. بطور منطقی این روش از مزایای هر دو روش استفاده نموده و معایب هر دو روش را تا حدودی تعديل مینماید.

روش‌هایی که در این تحقیق مورد توجه و مطالعه قرار گرفته‌اند، روش‌های صریح می‌باشند. بر طبق نظر آقای ساوجی [۱] و [۶] ویژگیها و مشخصه‌های بارز روش‌های موفق SBED عبارتند از؛ اطمینان‌پذیری^{۲۲}، مقاوم بودن در مقابل نویز^{۲۳}، دقت^{۲۴}، قابلیت تطبیق با شرایط جدید^{۲۵}، شادگی^{۲۶} و سهولت تحلیل^{۲۷}، امکان پیاده‌سازی زمان زنده^{۲۸} و عدم نیاز به اطلاعات قبلی از نویز^{۲۸}. بنابراین وقتی یک روش جدید ارائه و مورد مطالعه قرار می‌گیرد، می‌باشی با توجه به شاخصهای فوق محک زده شده و مورد ارزیابی قرار گیرد. ویژگیها و پارامترهای عده‌ایکه برای تشخیص ابتدا و انتهای گفتار مورد استفاده قرار می‌گیرند، نوعاً از جنس پارامترهایی است که در مرحله کدینگ یا بازناسی گفتار از آنها استفاده می‌شود. مهمترین این پارامترها، گین یا توان (نماینده انرژی یا توان سیگنال در عرض یک فریم). نرخ عبور از صفر ZCR^{۲۹} - انرژی باقیمانده از پیش بینی خطی LPC^{۳۰} - طول دوره گفتار TD^{۳۱} - اندازه پریودیک بودن PM^{۳۲} پارامترهای پوش طیف شامل MFCG^{۳۳} یا MFCC^{۳۴} می‌باشند. پارامتر نرخ عبور از صفر ZCR و انرژی باقیمانده از پیش بینی خطی LPC نوعاً برای SNR > ۲۰ dB کارایی دارند [۱] الی [۳]. معمولاً از دو پارامتر فوق برای تشخیص ابتدا و انتهای کلمات گفتاری تقریباً تمیز (صرفاً وجود نویزهای زمینه) استفاده می‌شود. پارامترهای عده‌ایکه برای تشخیص ابتدا و انتهای گفتار یا سیستمهای VAD برای SNR < ۲۰ dB نوعاً گین و طول دوره گفتار TD، اندازه پریودیک بودن PM و ضرایب طیفی و MFCC می‌باشند.

۱- بررسی و تحلیل الگوریتمهای SBED موجود

۱-۱- الگوریتمهایی که از انرژی و نرخ عبور از صفر ZCR استفاده مینمایند

در تمامی این الگوریتمها [۱] و [۴] الی [۹]، فرض بر این است که محدوده مشخصی در ابتدای فایل ضبط شده، سیگنال غیر گفتاری (سکوت یا نویز زمینه و ...) می‌باشد. سپس چندین سطح آستانه از انرژی و نرخ عبور از صفر را از روی فریم‌های ابتدای سیگنال بدست آورده و از آنها بعنوان نماینده نویز زمینه استفاده مینمایند. رایج‌ترین روش، بدست آوردن مقدار متوسط و انحراف معیار دو پارامتر انرژی و نرخ عبور از صفر می‌باشد. آنگاه با استفاده از یک دیاگرام گذرای چند حالت^{۳۵}، که تغییر حالت توسط سطوح آستانه فوق الذکر کنترل می‌شود [۳]، وجود سیگنال گفتار (ابتدا و انتهای کلمه) را تشخیص میدهد. برای تشخیص وقایع اکوستیکی غیر گفتاری پالسی (کلیک، پف و ...) از کوتاهی طول دوره آنها در مقایسه با گفتار استفاده مینمایند. در بعضی از این روشها [۱]، ابتدا فریمی از سیگنال که دارای بیشترین انرژی است، بعنوان نقطه قابل اعتماد برای شروع جستجو تعیین می‌گردد. آنگاه با استفاده از سطوح آستانه مربوط به انرژی و نرخ عبور از صفر نویزهای زمینه، ابتدا و انتهای گفتار را تشخیص میدهد.

این روشها با چند مشکل اساسی مواجه هستند. فرض میکنیم در چند فریم ابتدای فایل یا بافر ضبط شده صدا، وقایع اکوستیکی غیر مطلوب (غیر از نویزهای تداوم دار) مانند پف یا کلیک و یا ... باشد. پارامترهای آماری (مقدار متوسط و انحراف معیار) استخراج شده از آنها برای نویزهای تداوم دار غیر معتبر بوده و موجب خطا زیادی در تشخیص مکان ابتدا و انتهای گفتار و خطا در کلاس‌بندی فریم‌های گفتار به نویز می‌گردد. برای پرهیز از وقوع چنین وضعیت ناخواهاندی، آقای لی در مرجع [۳]، پیشنهاد استفاده از مدل‌سازی GMM به منظور جداسازی مقاوم نویزهای تداوم دار زمینه از وقایع اکوستیکی دیگر نموده است. روش پیشنهادی آقای لی مبتنی بر این فرضیه است که، سیگنال گفتار و نویز هر کدام توسط یک pdf گوسی تک مخلوط متمایز قابل نمایش هستند. فرضیه فوق نیز دو اشکال دارد، اولاً اینکه بازنمایی آماری سیگنال گفتار توسط یک مخلوط گوسی دارای خطای بسیار زیادی است (برای مدل‌سازی مناسب حداقل به سه مخلوط یکی برای فریم‌های باصداء، دومی برای فریم‌های بی‌صداء پائین‌گذر و سومی برای فریم‌های بی‌صداء بالا گذر نیازمند هستیم). ثانیاً، مدل پیشنهادی آقای لی فریم‌های بی‌صداء بالا گذر با انرژی پائین مانند ف، س، ح، ... را در $20 \text{ dB} < \text{SNR}$ جزء نویز زمینه مدل‌سازی مینماید. همچنین این روشها در مقابل نویزهای پریودیک، نویزهای غیر ایستان و نویزهایی که واریانس تغییرات انرژی آنها بالا باشد، دارای عملکرد ضعیفی می‌باشند.

۱-۲- الگوریتمهایی که از انرژی و اندازه پریودیک بودن PM استفاده مینمایند

فریم‌های با صدای گفتار دارای یک ویژگی مهم هستند که از آنها می‌توان برای شناسائی گفتار، با وجود نویزهای زمینه استفاده نمود. این ویژگی مهم آن است که، متوسط انرژی فریم‌های با صدا، معمولاً حدود 30 dB تا 10 dB بیشتر از متوسط انرژی فریم‌های بی‌صدای گفتار و نویزهای زمینه می‌باشد (حتی برای SNR های کمتر از 10 dB). تعدادی از الگوریتمهای VAD و SBED از این خاصیت برای تشخیص یک ناحیه مطمئن^{۳۶} گفتار از آن بهره میرند [۱] و [۱۰] الی [۱۲]. پس از تعیین ناحیه مطمئن، به کمک پارامترهای دیگر (انرژی و نرخ عبور از صفر و یا خروجی فیلترهای تشخیص لبه و ...)، ابتدا و انتهای گفتار را با دقت بیشتری تخمین می‌زنند. این روشها برای تعیین نواحی باصداء، از الگوریتمهای تخمین فرکانس پیچ استفاده مینمایند. بنابراین دقت و عملکرد این روشها، به مقدار زیادی به عملکرد الگوریتمهای تخمین فرکانس پیچ وابسته است. بنابراین جهت استفاده از کارآئی این روشها، می‌بایستی از الگوریتمهای دقیق و مطمئن تخمین فرکانس پیچ استفاده نمائیم. اغلب روشهای پیشنهادی موجود که از خاصیت پریودیک بودن PM استفاده مینمایند در مقابل نویزهای پریودیک و نویزهای غیر ایستان همهمه^{۳۷}، دارای عملکرد ضعیفی هستند.

۱-۳- الگوریتمهایی که از تغییرات انرژی طیفی استفاده مینمایند

[۲] و [۹] الی [۱۵]؛ اگر نویزهای تداوم دار تقریباً ایستان باشند (پریودیک یا غیرپریودیک)، در این صورت

پارامترهای پوش طیف آنها در طی فریم‌های متوازن نوعاً ثابت می‌باشند (یا دارای تغییرات کمتری نسبت به سیگنال گفتار هستند). در اغلب این روشها می‌بایستی تخمینی از میانگین و واریانس پارامترهای پوش طیف نویز تداوم دار در اختیار باشد. روش‌های ارائه شده در مراجع ذکر شده، با متوسط گیری از پارامترهای طیفی چند فریم آغازین فایل یا بافر ضبط شده، متوسط و انحراف معیار پارامترهای طیفی نویزهای تقریباً ایستان مانند MFCC و MFCG را بدست می‌آورند. آنگاه قدر مطلق اختلاف (یا توان دوم اختلاف) پارامترهای طیفی کلیه فریمها و مدل نویز را بدست می‌آورند. اگر این اختلاف از یک سطوح آستانه (که بصورت تجربی تعیین می‌شوند) بیشتر باشد، وجود سیگنال گفتار اعلام شده و سپس به کمک انرژی و سایر پارامترها، نقاط دقیق ابتدا و انتهای گفتار را تعیین می‌نمایند. این روشها برای نویزهای تقریباً ایستان (پریودیک و یا غیر پریودیک) دارای کارائی مناسبی می‌باشند. مشکل عمدۀ این روشها، کاهش عملکرد با تغییر تدریجی سطحی انرژی نویزهای تداوم دار و یا تغییر مشخصه طیفی نویزهای غیر ایستان می‌باشد.

۲- ارائه الگوریتم جدید MIP_SBED

الگوریتم MIP_SBED طبقاً صریح برای تخمین ابتدا و انتهای کلمات گفتاری هم در محیط‌های تمیز و همچنین در محیط‌های نویزی می‌باشد. الگوریتم MIP_SBED، مبتنی بر حداکثر استفاده از اطلاعات ذیل می‌باشد:

الف - استفاده از خاصیت پریودیک بودن حدود ۵۰-۷۰ درصد طول کلمات گفتاری

ب - استفاده از بالا بودن انرژی نواحی با صدا (صدا پریودیک) نسبت به نواحی بی‌صدا و نویزهای تداوم دار زمینه.

ج - استفاده از خاصیت حداکثر غیر ایستان بودن نواحی مرزبین واجهای با صدا و بی‌صدا در ابتدا و انتهای کلمات

د - استفاده از فیلتر غیرخطی مرتب کننده^{۳۹}، به منظور حداکثر جداسازی اطلاعات فریم‌های نویز تداوم دار زمینه از فریم‌های ایمپالسی (مانند پف، کلیک و ...) و فریم‌های بی‌صدا و با صدا گفتاری.

ه - استفاده از طول حداکثر واج بی‌صدا در ابتدای کلمات (حدود ۳۰۰ میلی ثانیه) و طول حداکثر مجموعه واجهای بی‌صدا در انتهای کلمات (حدود ۶۰۰ میلی ثانیه).

ر - استفاده از این نکته که طول دوره سکوت بین سیلابهای درون کلمه‌ای حداکثر ۳۰۰ میلی ثانیه می‌باشد.

ز - استفاده از این نکته که دوره سکوت بین دو کلمه متواالی حداقل می‌بایستی نیم ثانیه باشد.

ی - استفاده از حداقل و حداکثر طول دوره کلمات گفتاری

بارامترهای اصلی مورد استفاده در روش MIP-SBED عبارتند از: توان بر حسب (dB)، اندازه درست نمائی پریودیک بودن PLL، ویژگیهای پوش طیف (MFCC یا MFCG).

پارامتر توان و ضرایب MFCC یا MFCG در تمامی روش‌های آنالیز سیگنال گفتار (سیستم‌های بازشناسی گفتار و گوینده) استخراج شده و در اختیار می‌باشند. پارامتر درست نمائی پریودیک بودن موقعی استخراج می‌شود که بخواهیم فرکانس پیچ را استخراج نموده و یا وضعیت با صدا یا بی‌صدا بودن فریم‌های گفتار را تعیین نمائیم. خوب‌بختانه روش آنالیز این تحقیق برای استخراج ویژگیهای طیفی (ضرائب MFCC یا MFCG)، روش همزمان با پیچ^{۴۱} می‌باشد. در نتیجه استخراج فرکانس پیچ و اندازه درست نمائی پریودیک بودن جزئی از فرآیند مرحله آنالیز گفتار می‌باشد. بنابراین برای تشخیص ابتدا و انتهای گفتار روش MIP-SBED صرفاً از پارامترهای کلاسیک استخراج شده در مرحله آنالیز استفاده می‌نماییم.

هدف این تحقیق در ارائه روش MIP-SBED عبارت است از:

۱- مقاوم بودن روش در مقابل انواع نویزهای پریودیک و غیرپریودیک ($\text{SNR} \geq 5 \text{ dB}$).

۲- دقیق بودن تشخیص مرزهای ابتدا و انتهای گفتار

۳- امکان پیاده‌سازی بصورت دسته‌ای BM و همچنین زمان زنده RTM بر روی کامپیوترهای PC قابل دسترس. در بخش‌های زیر به شرح جزئیات الگوریتم پیشنهادی می‌پردازیم.

۳- روش‌های دقیق و مقاوم اندازه‌گیری پریودیک بودن PM

در مراجع [۱۰] تا [۱۲] روش‌های برای اندازه‌گیری پریودیک بودن فریم‌های متواالی گفتار ارائه شده است. این روشها اگر چه

دارای عملکرد مناسبی برای گفتار تمیز(یا برای SNR های بالا و متوسط) می باشد، اما برای SNR های پائین (بویژه بین صفر تا ۵) ضعیف می باشد. عملکرد پائین این روش موقعی تشید میشود که نویزهای محیطی غیر ایستان و تقریباً رنگی باشند. (مانند نویز همهمه). مرجع [۱۶] منبعی غنی از انواع روشهای تخمین فرکانس پیج و باصدابودن فریمهای گفتاری است که میتوان از این روشها برای اندازهگیری پریودیک بودن گفتار نیز استفاده نمود. بررسیها و مطالعات علمی و عملی محققین این نوشتار نشان میدهد که محاسبه $NCC^{۴۲}$ همبستگی متناظر نرمایی شده [۱۷] بر روی سیگنال گفتار میان گذر شده ^{۴۳}، پارامتری بسیار ارزشمند جهت اندازهگیری مقدار پریودیک بودن فریمهای متوالی سیگنال گفتار می باشد. مطالعات مقایسه ای و نتایج حاصل از آن در مرجع [۱۸] برای انتخاب روش دقیق و مقاوم تخمین فرکانس پیج، نیز مؤید انتخاب ما میباشد. با توجه به اینکه روش ارائه شده در مرجع [۱۷] و [۱۸] از سیگنال پائین گذر شده استفاده نمیماید و همچنین اصلاحات دیگری که در این تحقیق برای بهبود عملکرد اندازهگیری پریودیک بودن انجام پذیرفته، به شرح مختصر اندازهگیری پریودیک بودن PM فریمهای گفتار در طی این تحقیق می پردازم. مراحل استخراج اندازه پریودیک بودن PM بشرح زیر می باشد:

الف - سیگنال گفتار را از یک فیلتر میان گذر FIR ^{۴۴} از نوع پارکس مک کلان ^{۴۵} [۱۹] که مشخصات طیفی آن بشرح شکل (۱) می باشد عبور میدهیم. این فیلتر دارای فاز خطی است، لذا هیچ گونه اعوجاجی در فاز سیگنال گفتار اصلی ایجاد نمی نماید.

پا توجه باینکه انرژی اصلی فریمهای باصدای گفتار زیر KHz ۱ بوده و همچنین حداکثر فرکانس پیج قابل قبول سیستم Hz می باشد، فرکانس توقف فیلتر را KHz ۱ در نظر گرفتیم. بدین ترتیب ضمن حفظ انرژی قسمتهای پریودیک فریمهای باصدای سیگنال گفتار را نسبت به مؤلفه های غیر پریودیک سیگنال تحریک و همچنین نویزهای محیطی دارای مؤلفه های نزدیک D.C، بهبود بخشیده و مقاوم می نماید. سیگنالهای گفتار، در اغلب موقع بعلت غیر ایدهآل بودن میکروفون و یا بردهای D.C دیجیتايزر صوتی آغشته به هارمونیکهای اول و دوم برق شهر (Hz ۵۰-۶۰) و همچنین مؤلفه های D.C بایاس شده می باشند. استفاده از فیلتر میان گذر با مشخصه ارائه شده موجب حذف مؤلفه اول و دوم برق شهر و مقادیر D.C مزاحم خواهد شد. شکل (۲) یک نمونه از سیگنال باصدای اصلی و میان گذر شده آنرا نمایش میدهد.

ب - فرض میکنیم xb سیگنال میان گذر شده و (n) یک نمونه آن در فریم n م باشد. همچنین فرض می کنیم PP_max و PP_min پریودپیج حداقل و حداکثر سیستم باشد. چون فرکانس نمونه برداری سیگنال گفتار برای دیتاها این تحقیق KHz ۸ بوده و پریودپیج حداقل را ۲ و پریودپیج حداقل را ۱۶ میل ثانیه در نظر گرفتیم، در نتیجه محدوده حداقل و حداکثر تغییرات پریودپیج برابر $PP_{min} = 16$ و $PP_{max} = 128$ نمونه خواهد بود.

فرض میکنیم NCC(n,l) ضریب همبستگی متناظر نرمایی شده در فریم n م و برای برداری از سیگنال بطول l باشد. اگر (n,l) از نقطه xb (n, n + 1... n+l, n+l+1, ... x+2l) یک بردار بطول l باشد، آنگاه ضریب Zیر محاسبه میگردد.

$$NCC(n,l) = \frac{\sum_{i=1}^t xb(n+i).xb(n+1+i)}{\sqrt{\sum_{i=1}^t xb^2(n+i)} \cdot \sqrt{\sum_{i=1}^t xb^2(n+1+i)}} \quad (1)$$

در مرجع [۱۷]، طول بردارهای متوالی برابر ۱ لحاظ شده است. انتخاب τ باندازه ۱ موجب میشود که فرآیند تخمین پریود پیج و مقدار پریود یک بودن فریم آنالیز دو مرحله ای گردد. برای جلوگیری از اتفاق ذکر شده و کاهش حجم محاسبات، τ را بصورت زیر انتخاب میکنیم:

$$\tau = \begin{cases} 100 & \text{if } \tau \leq 100 \\ 1 & \text{if } \tau \geq 100 \end{cases} \quad (2)$$

طول ۱۰۰ نمونه معادل ۱۲/۵ میلی ثانیه در فرکانس نمونه برداری KHz ۸ می باشد. انتخاب طول ۱۰۰ نمونه موجب کاهش

اثرات فورمنت اول در تخمین فرکانس پیج و اندازه پریودیک بودن میگردد. همچنین با چند به یک کردن سیگنال میان گذر شده x_b به نسبت $\frac{1}{3}$ تا $\frac{1}{4}$ ، میتوان حجم محاسبات را نیز بیشتر کاهش داد. اندازه پریودیک بودن فریم n ام بصورت زیر محاسبه میشود:

$$PM(n) = \text{Max} \{ NCC(n,1) \} \quad (3)$$

$$l = pp_min \text{ تا } pp_max$$

ج - بر روی کانتور اندازه پریودیک بودن فریمها یعنی $PM(n)$ ها، دو اندازه هموار شده بشرح زیر تعریف مینمائیم:

$$RC_PM(n) = \frac{1}{L} \sum_{i=1}^L PM(n+i) \quad (4)$$

$$LC_PM(n) = \frac{1}{L} \sum_{i=1}^L PM(n-i) \quad (5)$$

$RC_PM(n)$ را اندازه پریودیک بودن متأثر از بافت راست 46 و $LC_PM(n)$ را اندازه پریودیک بودن متأثر از بافت چپ 47 می‌نامیم. L عمق نفوذ بافت سمت چپ یا راست فریم n ام می‌باشد. تجربیات محققین این نوشتار نشان میدهد که انتخاب L می‌بایستی بقسمی انجام پذیرد که طول بافت چپ یا راست کمتر از 60 میلی ثانیه و بزرگتر از 40 میلی ثانیه گردد. پارامتر LC_PM , RC_PM , PM در محدوده 1 و -1 تغییر مینماید. هر قدر پارامترهای فوق به یک نزدیکتر باشند، فریم مورد نظر دارای اندازه پریودیک بودن بیشتری خواهد بود در کاربردهای عملی یک سطح آستانه th_PM برای فریمهای با صدا در نظر میگیرند یعنی وقتی مقدار PM از سطح آستانه th_PM بزرگتر باشد، فریم آنالیز را با صدا و در غیر اینصورت بی صدا یا سکوت در نظر میگیرند. در کاربردهای عملی سطح آستانه th_PM در محدوده $0/85$ تا $0/825$ (بستگی به سطح نویزهای زمینه و فرکانس نمونه برداری) انتخاب میشود.

۲-۲- محاسبه توان میان گذر شده سیگنال گفتار

در مرجع [۱] و [۲]، دو نوع انرژی برای هر فریم سیگنال گفتار پیشنهاد شده است، اول، انرژی سیگنال در حوزه زمان دوم؛ انرژی سیگنال میانگذر شده در حوزه فرکانس. سپس با ترکیب وزنی این دو نوع انرژی، یک پارامتر بنام انرژی TF^{48} معرفی و از آن به عنوان نماینده انرژی سیگنال گفتار جهت متمایز سازی نویزهای زمینه از سیگنال گفتار استفاده شده است. تحقیقات محققین این نوشتار نشان میدهد که تلفیق دو نوع انرژی بصورت ذکر شده چندان ضروری نمی‌باشد. اما برای اینکه حتی الامکان انرژی نویزهای زمینه نسبت به انرژی سیگنال گفتار تضعیف گردد، میان گذر کردن سیگنال گفتار و سپس محاسبه انرژی آن ضروری بنظر میرسد. برای انجام این ایده فرض میکنیم $X(n+k)$ نمونه‌های سیگنال در فریم n ام باشد. توان سیگنال خام را بصورت زیر تعریف مینمائیم:

$$P(n) = \frac{\sum_{i=-1}^{i=+1} x^r(n+i).w^r(i+l)}{\sum_{i=-1}^{i=+1} w^r(i)} \quad (6)$$

که در آن $W(i)$ وزن پنجره همنیگ و $=2$ $i=0$ تا $i=+1$ طول پنجره همینگ در مرحله آنالیز سیگنال گفتار می‌باشد. حال فرض می‌کنیم $X(n+k)$ نمونه‌های FFT 49 سیگنال پنجره شده برای فریم n ام باشند.

نمونه‌های فوق را در یک تابع وزنی بصورت شکل (۳) ضرب مینماییم.

$$WX(n+k) = FW(k) \cdot X(n+k) \quad (7)$$

حال نسبت توان سیگنال اصلی در حوزه فرکانس به نسبت توان سیگنال وزن داده شده در حوزه فرکانس را مطابق رابطه زیر بدست می‌آوریم:

$$\gamma = \frac{\sum_{k=0}^{N-1} WX^*(n+k)}{\sum_{k=0}^{N-1} X^*(n+k)} \quad (8)$$

که در آن N طول نمونه‌های FFT می‌باشد (عددی بین ۲۵۶ تا ۱۰۲۴ برای فرکانس نمونه‌برداری ۸kHz) آنگاه توان سیگنال میان گذر شده را بصورت زیر بدست می‌آوریم:

$$BP(n) = \gamma \cdot P(n) \quad (9)$$

توان سیگنال میان گذر شده بر حسب dB نیز بصورت زیر تعریف و مورد استفاده قرار میدهیم:

$$LBP(n) = 10 \log_{10}(BP(n)) \quad (10)$$

به منظور کاهش واریانس توان نویز، برروی کانتور پارامتر توان $LBP(n)$ یک فیلتر پائین گذر هموار ساز مناسب اعمال مینماییم، توان هموار شده فریم n ام را اصطلاحاً با $SLBP(n)$ نمایش میدهیم. از روی کانتور توان هموار شده $SLBP(n)$ ، دو پارامتر جدید توان، بنامهای توان مرتب شده متأثر از بافت چپ و راست بشرح زیر تعریف مینماییم:

فرض میکنیم:

$$\{SLBP(n), \dots, SLBP(n+i), \dots, SLBP(n+L)\}$$

تعداد L نمونه از کانتور توان (سمت راست) فریم n ام باشند. این نمونه‌ها را بصورت صعودی مرتب مینماییم و نتیجه را $SRP_R(n,i)$ می‌نامیم.

$$SRP_R(n,i) = \{SLBP(n,j_i)\} \quad \text{that} \quad SLBP(n,j_i) \leq SLBP(n,j_{i+1}) \quad \text{و} \quad i = 0 \text{ تا } L \quad (11)$$

به طریق مشابه L نمونه از کانتور توان (سمت چپ) فریم n را بصورت صعودی مرتب نموده و نتیجه را $LP_L(n,i)$ می‌نامیم.

$$SLP_L(n,i) = \{SLBP(n-j_i)\} \quad \text{that} \quad SLBP(n-j_i) \leq SLBP(n-j_{i+1}) \quad (12)$$

بر روی بردار مرتب شده توان (متأثر از بافت راست)، دو پارامتر میانگین و واریانس توان پاییسن و بالا $LP_{L,L}(n)$ و $HP_{L,L}(n)$ بشرح زیر تعریف مینماییم:

$$RC-LP_L(n) = \frac{1}{L} \sum_{i=1}^L [SRP_L(n,i)] \quad (13)$$

$$RC-LP-SD_L(n) = \left\{ \frac{1}{L} \sum_{i=L-L_r}^L [SRP_L(n, i) - (RC_LP_{L_r}(n))^r] \right\}^{\frac{1}{r}} \quad (14)$$

$$RC-HP_L(n) = \frac{1}{L} \sum_{i=L-L_r}^L SRP_L(n, i) \quad (15)$$

$$RC-LP-SD_L(n) = \left\{ \frac{1}{L} \sum_{i=L-L_r}^L [SRP_L(n, i) - (RC_HP_{L_r}(n))^r] \right\}^{\frac{1}{r}} \quad (16)$$

بطریق مشابه پارامترهای فوق را برای کانتور توان متاثر از بافت چپ نیز تعریف مینماییم:

$$LC_LP_L(n) = \frac{1}{L} \sum_{i=-}^{L_r} SLP_L(n, i) \quad (17)$$

$$LC_LP_SD_L(n) = \left\{ \frac{1}{L} \sum_{i=-}^{L_r} [SLP_L(n, i) - (LC_LP_{L_r}(n))^r] \right\}^{\frac{1}{r}} \quad (18)$$

$$LC_HP_L(n) = \frac{1}{L} \sum_{i=L-L_r}^L SLP_L(n, i) \quad (19)$$

$$LC_HP_SD_L(n) = \left\{ \frac{1}{L} \sum_{i=L-L_r}^L [SLP_L(n, i) - (LC_HP_{L_r}(n))^r] \right\}^{\frac{1}{r}} \quad (20)$$

L را عمق نفوذ توان بافت چپ یا راست می‌گوئیم. L_1 و L_2 طول فریم‌ها برای متوسط‌گیری توان پائین و بالا بر روی داده‌های مرتب شده می‌باشند.

۳-۲- محاسبه نقاط با حداقل اطلاعات (MIP)

الف - انتخاب کاندید اولیه

فرض میکنیم نقطه A اولین فریم بر روی کانتور اندازه پریودیک بودن و کانتور توان هموار شده باشد (وقتی از سمت چپ به سمت راست حرکت می‌کنیم) که هر دو شرط زیر را دارا می‌باشد:

$$RC-PM(n=A) \geq th_{PM} \quad , \quad RC-HP_L(n=A) \geq th_{SP} \quad (21)$$

نقطه (A) را بعنوان کاندید اولیه نقطه شروع با حداقل اطلاعات (BMIP)^{۵۳} در نظر می‌گیریم. L را طوری انتخاب می‌نماییم که عمق نفوذ سمت راست حدود ۱۵۰ تا ۲۰۰ میلی ثانیه گردد. مقدار L را برابر $\sqrt{\frac{L}{3}}$ در نظر می‌گیریم. در این مرحله لازم است که تست غیر ایستانی^{۵۴} را انجام دهیم.

ب - اندازه گیری غیر ایستانی

فرض میکنیم $LC-LP-SP_L(n=A)$, $LC-LP_L(n=A)$, $CG(n,k)$ (۱۲ تا ۱ < k) گین کاتالهای طیفی در مقیاس amel برای بافت چپ نقطه A باشند. همچنین فرض میکنیم $n=A$ باشد. همچنین فرض میکنیم

عنوان نماینده اطلاعات پوش طیف فریم n باشند. مقادیر میانگین و واریانس پارامترهای طیفی کلیه فریمهای متولی از $n = A-L$ را که توان هموار شده آنها از سطح آستانه th_{NP} کمتر باشد محاسبه مینمائیم.

$$th_{NP} = LC_LP_L, (n = A) + LC_LP_SD_L, (n = A) \quad (22)$$

$$NCG(n = A, k) = \frac{\sum_{i=1}^s SP(n - j_i).cg(n - j_i, k)}{\sum_{i=1}^s SP(n - j_i)} ; \quad k = 1 \text{ تا } 12 \quad (23)$$

s برابر مجموع تعداد فریمهای است که توان هموار شده آنها (SP) از سطح آستانه th_{NP} کمتر میباشد.

$$NCG\text{-VAR}(n = A, k) = \left\{ \frac{\sum_{i=0}^s S^2 P(n - j_i)[cg(n - j_i, k) - NCG(n = A, k)]^2}{\sum_{i=0}^s S^2 P(n - j_i)} \right\} ; \quad k = 1 \text{ تا } 12 \quad (24)$$

در محاسبه روابط (23) و (24) فرض بر این است که $SP(n - j_i) \leq th_{NP}$ میباشد ($i = 1 \text{ تا } s$).
مقدار $NCG(n = A, k)$ و $NCG\text{-VAR}(n = A, k)$ عنوان میانگین و واریانس طیف نویز زمینه تداومدار در نظر گرفته میشود.
حال با فرض اینکه $(k = 1 \text{ تا } 12)$ مقادیر میانگین پارامترهای طیفی نویز زمینه است، واریانس نسبی (پارامترهای فوق) یک قطعه از سیگنال از نقطه $n = A+M_1$ تا $n = A+M_1$ بشرح زیر بدست میآوریم (طوری انتخاب میشود که طول قطعه حدود ۲۰۰ تا ۱۵۰ میلی ثانیه گردد).

$$CG\text{-VAR}(n = A, k) = \frac{\sum_{i=M_1}^{i=M_2} S^r P(n + i)[cg(n + i, k) - NCG(n = A, k)]^r}{\sum_{i=M_1}^{i=M_2} S^r P(n + i)} \quad (25)$$

با استفاده از دو دسته واریانس، یکی نماینده سطح تغیرات پارامترهای طیفی نویز زمینه تداومدار و دیگری نماینده انحراف سیگنال تحت بررسی از نویز تداومدار، پارامتری بنام اندازه غیر ایستانی (NSM) ($n = A$) بشرح زیر تعریف مینمائیم

$$NSM(n = A) = \frac{1}{12} \sum_{k=1}^{12} \frac{CG\text{-VAR}(n = A, k)}{NCG\text{-VAR}(n = A, k)} \quad (26)$$

چنانچه مشخصات طیف قطعه مورد بررسی تقریباً مساوی طیف نویز تداومدار باشد (پریود یک یا غیر پریودیک)، مقدار $NSM(n = A)$ در محدوده عدد یک در نوسان میباشد. ولی چنانچه قطعه مورد نظر مربوط به آوای مصوت^{۴۷} یک تلفظ گفتاری باشد، مقدار $NSM(n = A)$ بسمت عددی بزرگتر از یک سوق پیدا میکند. بنابراین با طراحی یک سطح آستانه مناسب و بزرگتر از یک میتوان مقدار غیر ایستانی را مشخص نمود. فرض میکنیم سطح آستانه غیر ایستانی برای th_{NSM} باشد (که بطور تجربی تعیین میگردد).

ج - تعیین نقطه شروع و پایانی M IP یک تلفظ گفتاری

فرض میکنیم که نقطه B فریمی باشد که شرایط زیر را دارا بوده (سه شرط حداقل اندازه توان، حداقل اندازه پریودیک

بودن و حداقل اندازه غیر ایستانی) و فریم ماقبل آن یکی از شروط فوق را حائز نمیباشد.

$$[(RC_PM(n = B) \geq th_{PM} \text{ and } RC_HP_{L_2}(n = B) \geq th_{SP} \text{ and } NSM(n = B) \geq th_{NSM})]$$

$$[RC_PM(n = B - 1) < th_{PM} \text{ or } RC_HP_{L_2}(n = B - 1) < th_{SP} \text{ or } NSM(n = B - 1) < th_{NSM})] \quad (27)$$

نقاط فوق بازاء هر سیلاب معمولاً یکبار اتفاق افتاده و در ابتدای واج مصوت سیلاب قرار می‌گیرند. این نقاط را اصطلاحاً نقاط MIP شروع می‌نامیم. هر کلمه بر حسب اینکه از چند سیلاب تشکیل شده باشد، چندین نقطه MIP شروع در آن آشکار سازی خواهد شد. اولین نقطه MIP شروع کلمه (یا تلفظ گفتاری) می‌نامیم. چنانچه یک واقعه اکوستیکی (پف، کلیک و ته سرفه و ...) زنگ تلفن، صدای موتور کولر، پنکه و فن کامپیوتر ...) داشته باشیم که نقطه MIP شروع برای آن قابل تعیین نباشد (یعنی چهار شرط ذکر شده را بطور همزمان ارضاء ننماید). بعنوان وقایع اکوستیکی غیر گفتاری لحاظ شده و از بازشناسی آن صرفنظر مینماییم.

برای تعیین نقاط MIP پایانی، بطريق مشابه عمل مینماییم. البته برای تعیین نقاط MIP پایانی، از اندازه توان، اندازه پریودیک بوده و اندازه غیر ایستانی بافت چپ استفاده مینماییم. بنابراین برای تعیین نقاط MIP پایانی، از شروط زیر استفاده مینماییم:

$$[LC_PM(n = E) \geq th_{PM} \text{ and } LC_HP_{L_1}(n = E) \geq th_{SP} \text{ and } NSM(n = E) \geq th_{NSM}] \text{ and} \quad (28)$$

$$[LC_PM(n = E + 1) < th_{PM} \text{ or } [LC_HP_{L_2}(n = E + 1) < th_{SP} \text{ or } NSM(n = E + 1) < th_{NSM}]]$$

در محاسبه اندازه غیر ایستانی نقاط MIP پایانی، از مدل نویز زمینه تداومدار اولین نقطه MIP شروع استفاده مینماییم. شکل (۴) و (۵) نقاط MIP شروع و پایانی یک کلمه (تک سیلابی) و یک کلمه (دو سیلابی) در دو حالت $SNR \approx 10\text{dB}$ و $SNR \geq 30\text{dB}$ نویز سفید را نشان میدهد. ملاحظه میشود که نقاط فوق در مقابل نویز بسیار مقاوم و مطمئن عمل مینمایند.

۴-۴- تشخیص ابتدا و انتهای تلفظ گفتاری

فرض میکنیم B_1 اولین نقطه MIP شروع یک تلفظ گفتاری باشد. هر کلمه از چندین سیلاب تشکیل شده است. سیلابهای زبان فارسی دارای ساختاری CV^{58} و CVC^{59} میباشند. بنابراین هر کلمه‌ای با یک واج غیر مصوت آغاز میشود. طبق تحقیقات تجربی محققین این نوشتار، واجهای غیر مصوت غیر صدادار طویل که در ابتدای کلمات واقع میشوند شامل واجهای (س، ح، ف، ش، خ، ج، ...) میباشند. طبق اندازه‌گیری بعمل آمده فاصله فریم شروع واجهای فوق الذکر تا نقطه MIP شروع هر کلمه حداقل 300 میلی ثانیه میباشد. بنابراین با قطعیت کافی میتوان گفت که در محاوره عادی، ابتدای کلمات حداکثر حدود 300 میلی ثانیه مقابل نقطه MIP شروع کلمه آغاز میشوند. در نتیجه چنانچه نقطه MIP شروع کلمه در اختیار باشد، کافی است جستجوی تشخیص ابتدای کلمه را صرفاً از 300 میلی ثانیه مقابل نقطه MIP شروع کلمه اجرا نماییم. همچنین طول دوره مجموعه واجهای غیر مصوت غیر صدادار که در انتهای کلمات واقع میشوند حداقل 600 میلی ثانیه بعد از نقطه MIP پایانی کلمه میباشند. بنابراین چنانچه نقطه MIP پایانی کلمه در اختیار باشد، کافی است جستجوی تشخیص انتهای کلمه را صرفاً از 600 میلی ثانیه بعد از نقطه MIP پایانی کلمه اجرا نماییم. حال برای تشخیص ابتدا و انتهای تلفظ گفتاری، و همچنین متمایزسازی فریمهای گفتاری از نویزهای زمینه (بین سیلابی و غیره ...) از ایده‌های مطرح شده در مراجع [۳] و [۹] بشرح زیر استفاده مینماییم.

فرآیند کلاس‌بندی گفتار از نویز زمینه را بر روی کلیه فریمهای موجود در بازه زمانی 300 میلی ثانیه قبل از نقطه MIP آغازین تا 600 میلی ثانیه بعد از نقطه MIP پایانی تلفظ گفتاری اجرا مینماییم. فرض میکنیم $NSM(n)$ اندازه غیر ایستانی فریم n نسبت به نویز زمینه تداومدار باشد (با فرض $M_1 = 1$ در رابطه 25). همچنین NP و $NVAR$ مقادیر متوسط و انحراف معیار توان (بر حسب dB) نویز زمینه تداومدار باشد (که در نقطه MIP آغازین تلفظ گفتاری تخمین زده میشود). البته چنانچه $NVAR$ از

یک سطح آستانه حدود (dB ۰/۵) کمتر باشد آنرا با سطح آستانه فوق جایگزین می‌کنیم. همچنین (n) SP توان هموار شده فریم n ام (بر حسب dB) و NF-COUNT یک کانتر برای شمارش تعداد فریمهای سکوت یا نویز زمینه و SF-COUNT یک کانتر برای شمارش تعداد فریمهای گفتاری باشند.

فریم n ام دریازه زمانی ذکر شده را موقعی بعنوان فریم گفتاری کلاس‌بندی مینمائیم که یکی از شروط زیر را دارا باشد:

$$SP(n) \geq 1/75 \quad NVAR + NP \quad \text{الف}$$

$$SP(n) \geq NP + NVAR \quad \text{and} \quad NSM(n) \geq 1/25 \quad \text{ب}$$

$$SP(n) \geq NP \quad \text{and} \quad NSM(n) \geq 1/75 \quad \text{ج}$$

کلاس‌بندی فریمهای سیگنال دریافتی به یکی از دو کلاس گفتاری و غیرگفتاری بر مبنای منطق ذکر شده انجام می‌پذیرد. به منظور تشخیص فواصل سکوت درون کلمه‌ای و همچنین تشخیص انتهای تلفظ گفتاری، فرآیند کلاس‌بندی را در سه ناحیه متوالی بطور متمایز انجام میدهیم.

الف - کلاس‌بندی فریمهای در ناحیه ماقبل نقطه MIP آغازین کلمه (برای طول دوره‌ای در حدود حداکثر ۳۰۰ میلی ثانیه)

ب - کلاس‌بندی فریمهای در ناحیه ما بین نقطه MIP آغازین و پایانی کلمه

ج - کلاس‌بندی فریمهای در ناحیه ما بعد نقطه MIP انتهای کلمه (برای طول دوره‌ای در حدود حداکثر ۶۰۰ میلی ثانیه).

در ناحیه الف؛ قبل از فرآیند کلاس‌بندی، کانترهای SF-COUNT و NF-COUNT را صفر می‌کنیم سپس کلاس‌بندی فریمهای را بر مبنای منطق ذکر شده انجام میدهیم. بازه هر بار کلاس‌بندی فریمهای به گفتار، کانتر SF-COUNT یکی افزود می‌شود. بعد از اینکه ≥ 1 -SF-COUNT گردید، کانتر NF-COUNT نیز در صورت مشاهده هر بار فریم نویز زمینه یکی افزایش می‌یابد. پس از رسیدن به نقطه MIP آغازین کلمه، چنانچه NF-COUNT > SF-COUNT گردد، فریمهای شروع تا نقطه پیوسته گفتار در نزدیکی نقطه MIP آغازین بعنوان سکوت یا نویزهای اکوستیکی غیر گفتاری (کلیک، پف و ...) در نظر گرفته می‌شود.

در ناحیه ب؛ کانترهای SF-COUNT و NF-COUNT را صفر می‌کنیم. با مشاهده یک فریم گفتاری (بر مبنای منطق کلاس‌بندی ذکر شده)، به کانتر SF-COUNT یکی می‌افزاییم. همچنین با مشاهده یک فریم غیر گفتاری (سکوت یا نویز زمینه)، به کانتر NF-COUNT یکی اضافه می‌کنیم. در طی انجام فرآیند فوق دو وضعیت ممکن است اتفاق بیافتد؛

۱- تعداد فریمهای غیر گفتاری NF-COUNT از یک سطح آستانه بیشتر گردد (حدوداً ۴۰۰ میلی ثانیه، یعنی حدود ۱۰۰ میلی ثانیه بیشتر از حداکثر فاصله سکوت سیالهای متواالی درون کلمه‌ای). در این صورت آخرین فریمی که گفتار کلاس‌بندی شده است به عنوان انتهای گفتار تلقی شده و فرآیند تشخیص انتهای گفتار خاتمه می‌یابد.

۲- به یک نقطه MIP پایانی می‌رسیم و در این حالت تعداد فریمهای غیر گفتاری NF-COUNT صفر بوده و یا عدد کوچکی می‌باشد. در این صورت کلاس‌بندی ناحیه (ج) را بشرح زیر ادامه میدهیم.

در ناحیه ج؛ مجدداً کانترهای SF-COUNT و NF-COUNT را صفر می‌کنیم. بر مبنای منطق ذکر شده، فریمهای را به کلاس‌های گفتاری و غیر گفتاری کلاس‌بندی می‌کنیم و کانترهای منتظر را (با مشاهده هر کلاس) یکی افزایش میدهیم. در طی انجام فرآیند فوق دو وضعیت ممکن است اتفاق بیافتد؛

۱- تعداد فریمهای غیر گفتاری NF-COUNT از یک سطح آستانه بیشتر گردد (حدود ۴۰۰ میلی ثانیه)، در این صورت آخرین فریمی که گفتار کلاس‌بندی شده است به عنوان انتهای گفتار تلقی شده و فرآیند تشخیص انتهای گفتار خاتمه می‌یابد.

۲- تعداد فریمهای غیر گفتاری NF-COUNT کمتر از ۳۰۰ میلی ثانیه است، ولی NF-COUNT + SF-COUNT بیشتر از ۶۰۰ میلی ثانیه گردیده است. در این صورت آخرین فریم گفتاری بعنوان فریم انتهای تلفظ گفتاری تلقی شده و فرآیند تشخیص انتهای تلفظ گفتاری خاتمه می‌یابد.

تشخیص نقطه MIP پایانی تلفظ گفتاری

تشخیص نقطه MIP آغازین تلفظ گفتاری نسبتاً ساده است. زیرا اولین نقطه MIP شروع که با آن مواجه شدیم بعنوان نقطه MIP آغازین تلفظ گفتاری در نظر گرفته می‌شود. اما در طی فرآیند کلاس‌بندی فریمهای به دو کلاس گفتار و غیر گفتار

(سکوت، نویز زمینه) با نقاط MIP پایانی متعددی مواجه میشویم (بر حسب اینکه تلفظ گفتاری از چند کلمه یا چندین سیلاب تشکیل شده باشد). در این حالت میباشتی آخرین نقطه MIP پایانی را برای آن تلفظ گفتاری با دقت و اطمینان بالائی تعیین نمائیم نقطه MIP پایانی درون کلمه‌ای که حائز یکی از شرایط زیر باشد بعنوان نقطه MIP پایانی تلفظ گفتاری در نظر گرفته میشود:

- ۱- برای یک دوره حدود ۵۰۰ میلی ثانیه بعد از آن، بیشتر از ۸۵ درصد فریمها، غیر گفتاری کلاس‌بندی شده باشند.
- ۲- برای یک دوره حدود ۷۰۰ میلی ثانیه‌ای بعد از آن نقطه، بیشتر از ۹۰ درصد فریمها، غیر گفتاری یا گفتاری ولی غیر پریودیک (بی صدا) کلاس‌بندی شده باشند.

۳- نتایج پیاده‌سازی

فرکانس نمونه‌برداری تمامی داده‌های گفتاری مورد استفاده KHz ۸ بوده و نمونه‌ها بصورت PCM ۱۶ بیتی ضبط شده‌اند. پایگاه داده مورد استفاده ۱۵۰۰ کلمه پر مصرف در کاربردهای IT^{۶۰} و سرویسهای مخابرایی بوده است. داده‌های گفتاری توسط میکروفون جهتی خوب و تحت شرایط SNR > ۳۰ dB ضبط شده‌اند. ۱۰ نفر گوینده (۷ نفر مرد و ۳ نفر زن) فرمانها و تقاضاهای صوتی را (با ۱۰ بار تکرار از هر فرمان) تلفظ نموده‌اند. بین هر دو فرمان یا تقاضای صوتی حداقل یک ثانیه سکوت برقرار بوده است. برای ارزیابی مقاوم بودن الگوریتمها، از دو گروه نویز غیرپریودیک (نویز سفید^{۶۱}، نویز همهمه^{۶۲}، نویز صورتی^{۶۳}، نویز اداری) و نویز پریودیک (زنگ تلفن، صدای موتور کولر، صدای موتور یخچال) با نسبت SNR های مختلف (۲۰ و ۱۵ و ۱۰ و ۵) استفاده نمودیم. برای اضافه کردن نویزها به سیگنال از روشهای مندرج در توصیه نامه‌های ITU استفاده نمودیم به منظور بررسی عملکرد روش ارائه شده در مقابل روشهای مؤثر دیگر، دو روش جدید و مطرح در مرجع [۱] و [۳] نیز پیاده‌سازی شده‌اند. در بخش‌های زیر روش مندرج در مرجع [۱] را BE۱ و روش مندرج در مرجع [۳] را BE۲ و روش ارائه شده در این تحقیق را MIP نامیدیم. آزمونهای متعددی برای ارزیابی عملکرد روش MIP در تشخیص ابتدا و انتهای گفتار بشرح زیر انجام دادیم:

الف - آزمون‌های ارزیابی دقت تشخیص

ابتدا و انتهای کلیه کلمات گفتاری ضبط شده از همه گویندگان بصورت دستی (با استفاده از نرم‌افزارهای بسیار دقیق و بکارگیری افراد خبره) بر چسب زده شده‌اند. در آزمون اول هدف بررسی دقت تشخیص الگوریتم‌ها بوده است. در این آزمون بر چسب دستی بعنوان بر چسب مرجع مدنظر قرار گرفته است. اختلاف زمانی بر چسب الگوریتم‌ها در مقایسه با برچسب دستی بعنوان معیار دقت، مورد توجه قرار گرفته است. جدول (۱) مقادیر متوسط و انحراف معیار اختلاف زمانی برچسبهای اتوماتیک و دستی را برای $SNR \geq ۳۰ dB$ (بدون اضافه کردن نویز) برای تشخیص ابتدای کلمه را (بر حسب میلی ثانیه) نشان میدهد. جدول (۲) این اختلاف زمانی را برای تشخیص انتهای کلمات گفتاری نشان میدهد. با ملاحظه جداول (۱) و (۲) مشاهده میشود که؛ دقت روش MIP برای گفتار تمیز (بدون اضافه کردن نویز) بهتر از روشهای BE۱ و BE۲ می‌باشد. همچنین مشاهده میشود که دقت هر سه روش برای تشخیص ابتدای کلمه بهتر از انتهای کلمه میباشد. برای ارزیابی بهتر روشهای، یک سیستم بازشناسی گفتار گسسته بصورت وابسته به گوینده با استفاده از مدل‌سازی HMM پنج حالته طراحی و پیاده‌سازی نمودیم. نتایج دقت بازشناسی در جدول (۳) درج گردیده است. در این آزمون از گفتار تمیز (بدون اضافه کردن نویز) استفاده نموده و برای هر حالت مدل، ۴ مخلوط^{۶۴} طراحی کرده‌ایم. ۱۲ ضریب MFCC و ۱۲ ضریب مشتق اول آن و مشتق لگاریتم گین با آنالیز PLP استخراج شده‌اند، بعنوان ویژگی طیفی مورد استفاده قرار گرفته‌اند.

از روی جدول (۳) مشاهده میشود که دقت بازشناسی بروش برچسب اتوماتیک MIP در حد روش دستی و بهتر از روشهای اتوماتیک دیگر می‌باشد.

ب - آزمونهای ارزیابی مقاوم بودن تشخیص ابتدا و انتهای گفتار در مقابل نویزهای غیرپریودیک

در این آزمون با اضافه کردن انواع نویزهای غیرپریودیک با نسبت SNR مختلف، مقاوم بودن الگوریتم‌ها در مقابل نویز را مورد ارزیابی قرار دادیم. جدول (۴) نتایج این آزمونها را برای انواع نویزهای غیرپریودیک نشان میدهد. با مروری بر نتایج حاصل، مشاهده میشود که روش MIP دارای عملکردی نزدیک برچسب زدن دستی و مقاوم‌تر از روشهای دیگر می‌باشد.

همچنین ملاحظه میشود، بهبودی که حاصل شده است برای انواع نویزهای غیرپریودیک و برای انواع سطوح SNR برقرار است. همچنین مشاهده میشود که بدترین نوع نویز در بازناسی گفتار، نویز غیر ایستان همهمه میباشد.

ج - آزمونهای ارزیابی مقاوم بودن تشخیص ابتدا و انتهای گفتار در مقابل نویزهای پریودیک نویزهای پریودیک که نوعاً در محیطهای اداری و منزل با آن مواجه هستیم، صدای زنگ تلفن، صدای فن، (فن کوئل) صدای موتور کولر میباشند. این صداها تلفیقی از نویزهای سفید (با توان کمتر) و نویزهای پریودیک (با توان بیشتر) میباشند. جداول (۸ تا ۱۰) نتایج بازناسی را برای سه نوع آزمون نویز پریودیک و سطوح SNR مختلف نشان میدهد با مروری بر نتایج حاصل مشاهده میکنیم که روش MIP در مقابل نویزهای پریودیک نیز مقاوم تر از روشهای دیگر میباشد.

ع- جمع‌بندی و نتیجه گیری

در این تحقیق روشی مؤثر و مطمئن و دقیق برای تشخیص ابتدا و انتهای گفتار ارائه نمودیم. از ویژگیهای مهم روش ارائه شده آن است که؛ از تمامی اطلاعات مفید و قابل ارائه سیگنال گفتار شامل؛ پریودیک بودن، بالا بودن سطح انرژی قسمتهای با صدا نسبت به قسمتهای بی صدا، اندازه غیر ایستانی قسمتهای گفتار نسبت به نویزهای تداومدار محیطی و ... به نحو مؤثری برای جداسازی گفتار از نویزهای زمینه استفاده مینماید. یکی از ویژگیهای مؤثر روش ارائه شده آن است که هم برای نویزهای پریودیک و هم برای نویزهای غیر پریودیک دارای دقت لازم میباشد. از ویژگیهای دیگر روش ارائه شده آن است، که هم برای سیستم‌های زمان زنده و هم برای سیستم دسته‌ای قابل پیاده‌سازی است. یکی از مشکلات عمدۀ روشهای دیگر، تخمین پارامترهای مدل نویز زمینه تداومدار است. در اغلب روشهای کلاسیک، از اطلاعات چندین فریم آغازین ضبط برای مدل‌سازی نویز استفاده میشود. در روش MIP، مشخصات نویز زمینه تداومدار با بهترین دقت و مستقل از وقایع اکوستیکی اطراف گفتار تخمین زده میشود. همچنین این تخمین برای کاربردهای زمان زنده که فرآیند ضبط ادامه دارد (با فواصل سکوت بیش از یک ثانیه) و امکان دارد وضعیت نویز زمینه تغییر یابد بسیار مفید و مؤثر است. برای ارزیابی کارائی روش MIP در تشخیص ابتدا و انتهای گفتار، یک سیستم بازناسی گفتار وابسته به گوینده با دایره لغات ۱۵۰۰ کلمه‌ای طراحی و پیاده‌سازی گردید. تمامی نتایج حاصل برای انواع نویزهای پریودیک و غیرپریودیک و همچنین برای انواع سطوح توان نویز، مؤید دقت و برتری عملکرد روش MIP نسبت به روشهای کلاسیک موجود میباشد.

جدول (۱) اختلاف زمانی (بر حسب میلی ثانیه) بر چسب دستی و روشهای اتوماتیک در تشخیص ابتدای گفتار.

روش	متوسط	انحراف معیار
BE1	۲۰/۸	۲۱/۵
BE2	۱۴/۵	۱۵/۶
MIP	۸/۷	۱۰/۴

جدول (۲) اختلاف زمانی (بر حسب میلی ثانیه) بر چسب دستی و روشهای اتوماتیک در تشخیص انتهای گفتار.

روش	متوسط	انحراف معیار
BE1	۳۵/۷	۳۰/۸
BE2	۲۸/۴	۲۲/۵
MIP	۱۷/۶	۱۵/۴

جدول (۳) نتایج بازناسی گفتار تمیز (بروش HMM).

روش	متوسط دقت بازناسی کلمات مختلف	انحراف میاردن دقت بازناسی کلمات مختلف
برچسب دستی	۹۷/۳	۲/۴
BE1	۹۴/۳	۳/۸
BE2	۹۵/۷	۳/۱
MIP	۹۶/۹	۲/۶

جدول (۴) نتایج دقت بازشناسی برای نویز غیر پریودیک سفید(White Noise).

روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۸	۹۵/۳	۹۴/۱	۹۱/۸
BE۱ روش	۹۱/۲	۸۸/۷	۸۵/۴	۸۱/۶
BE۲ روش	۹۴/۳	۹۱/۵	۸۸/۳	۸۴/۲
MIP روش	۹۶/۳	۹۴/۵	۹۲/۷	۸۹/۸

جدول (۵) نتایج دقت بازشناسی برای نویز غیر پریودیک صورتی(Pink Noise).

روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۷	۹۵/۲	۹۳/۹	۹۱/۲
BE۱	۹۱/۰	۸۸/۳	۸۵/۰	۸۰/۲
BE۲	۹۴/۱	۹۱/۲	۸۷/۸	۸۳/۲
MIP	۹۶/۲	۹۴/۳	۹۲/۲	۸۹/۵

جدول (۶) نتایج دقت بازشناسی برای نویز غیر پریودیک محیط اداری(Office Noise).

روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۹	۹۵/۵	۹۴/۳	۹۲/۱
BE۱	۹۱/۴	۸۹/۰	۸۵/۵	۸۱/۹
BE۲	۹۴/۵	۹۱/۷	۸۸/۶	۸۴/۷
MIP	۹۶/۵	۹۴/۷	۹۳/۱	۹۰/۱

جدول (۷) نتایج دقت بازشناسی برای نویز غیر پریودیک هممه(Babble Noise).

روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۲	۹۴/۴	۹۰/۳	۸۷/۶
BE۱	۹۰/۲	۸۵/۷	۸۲/۴	۷۸/۱
BE۲	۹۳/۳	۸۹/۸	۸۳/۷	۷۹/۹
MIP	۹۵/۸	۹۳/۵	۸۹/۵	۸۵/۷

جدول (۸) نتایج دقت بازشناسی برای نویز پریودیک زنگ تلفن.

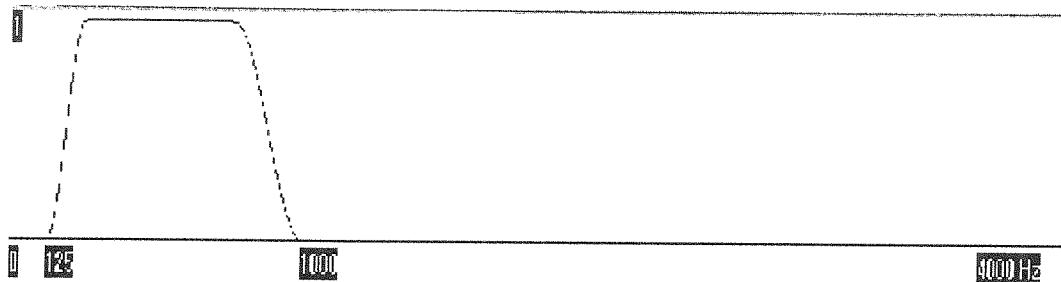
روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۸	۹۵/۴	۹۳/۷	۹۰/۱
BE۱	۹۱/۶	۸۹/۹	۸۴/۲	۸۰/۴
BE۲	۹۴/۷	۹۱/۸	۸۷/۳	۸۱/۶
MIP	۹۶/۵	۹۴/۹	۹۲/۴	۸۸/۸

جدول (۹) نتایج دقت بازشناسی برای نویز پریودیک فن کوئل.

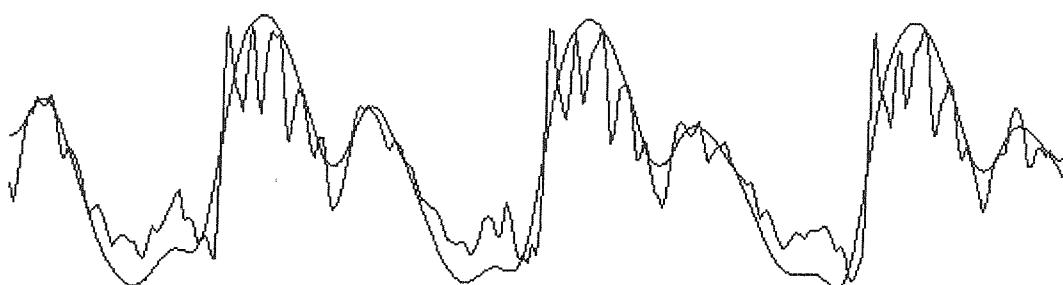
روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۴	۹۵/۲	۹۳/۹	۹۱/۴
BE۱	۹۱/۱	۸۹/۲	۸۵/۱	۸۱/۱
BE۲	۹۴/۲	۹۱/۷	۸۸/۴	۸۲/۷
MIP	۹۶/۱	۹۴/۳	۹۲/۸	۸۹/۷

جدول (۱۰) نتایج دقت بازشناسی برای نویز پریودیک موتور کولر.

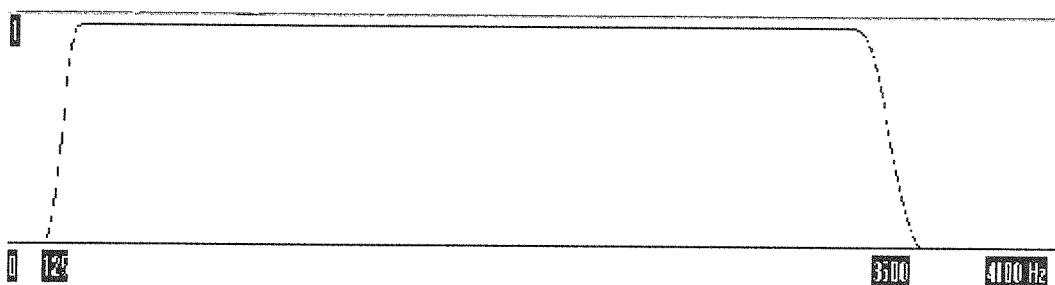
روش	SNR = ۲۰ dB	SNR = ۱۵ dB	SNR = ۱۰ dB	SNR = ۵ dB
بر چسب دستی	۹۶/۳	۹۵/۴	۹۴/۱	۹۱/۸
BE۱	۹۱/۳	۸۹/۶	۸۵/۴	۸۱/۹
BE۲	۹۴/۴	۹۱/۹	۸۸/۷	۸۴/۱
MIP	۹۵/۸	۹۴/۵	۹۳/۱	۸۹/۹



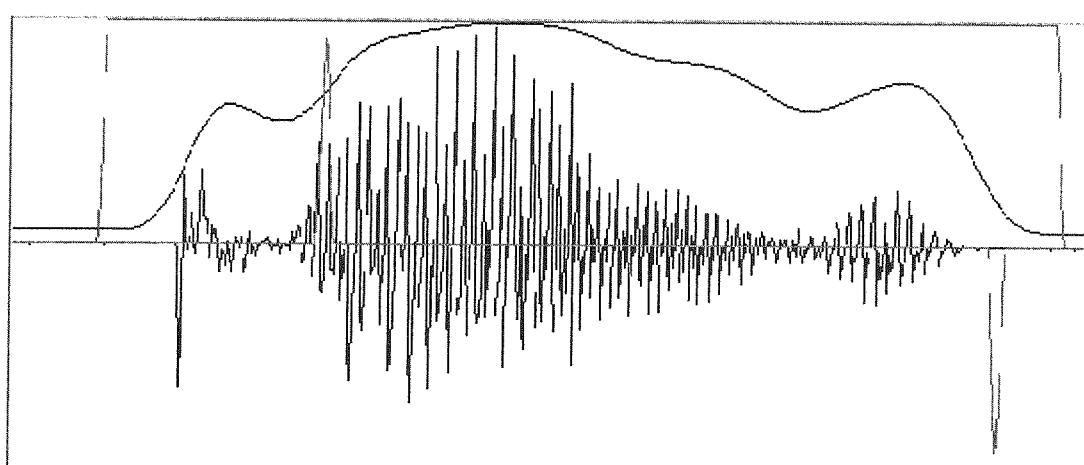
شکل (۱) پاسخ فرکانسی فیلتر FIR میانگذر برای تخمین فرکانس پیچ.



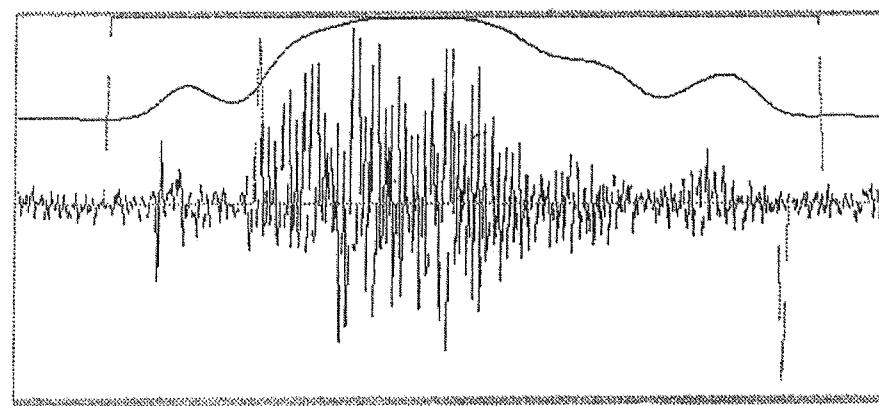
شکل (۲) یک قطعه از سیگنال با صدا، همراه با سیگنال میانگذر شده معادل.



شکل (۳) تابع وزنی در حوزه فرکانس برای محاسبه توان سیگنال.

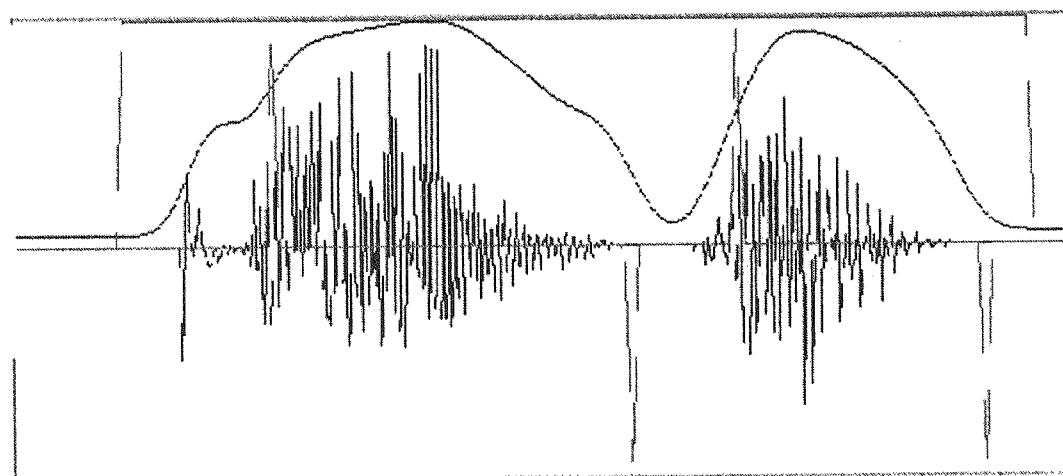


الف - کلمه تک سیلابی و $\text{SNR} \geq 20 \text{ dB}$

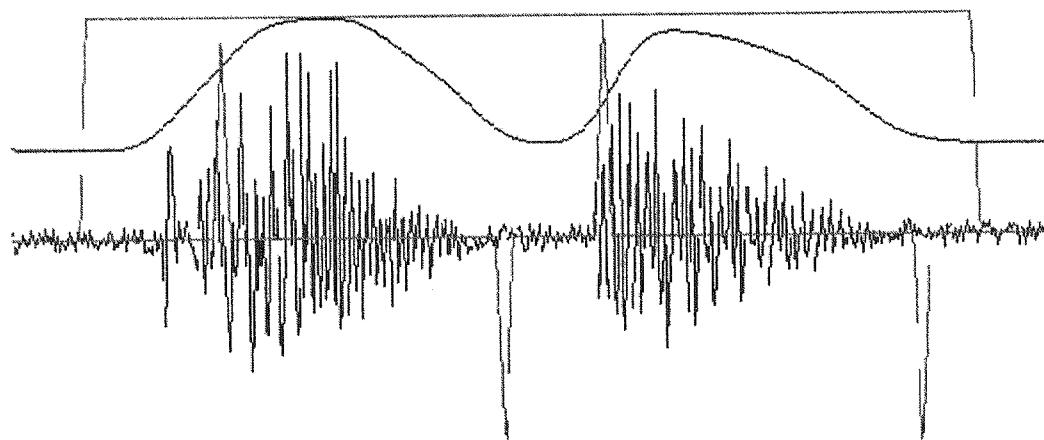


ب - کلمه تک سیلابی و $\text{SNR} \geq 10 \text{ dB}$

شکل (۴) نقاط MIP شروع و پایانی برای کلمه تک سیلابی.



الف - کلمه دو سیلابی و $\text{SNR} \geq 20 \text{ dB}$



ب - کلمه دو سیلابی و $\text{SNR} \geq 10 \text{ dB}$

شکل (۵) نقاط MIP شروع و پایانی برای کلمه دو سیلابی.

واژه‌نامه‌ها

1-Nonspeech Acoustic Events

2- Background noise

3- Speech Begin and Endpoint Detection

4- Endpoint Detection

5- Speech Activity Detection

6- Voiced Activity Detection

7- Impulse Noise

8- Continuant Noise

- 9- White Noise
- 10- Color Noise
- 11- Stationary
- 12- Nonstationary
- 13- Fixed Level Noise
- 14- Variable Level Noise
- 15- Batch Mode
- 16- Real Time Mode
- 17- Explicit
- 18- Implicit
- 19- Hybrid
- 20- Hidden Markov Model Alignment
- 21- Dynamic Time Warping Alignment
- 22- Reliability
- 23- Robustness
- 24- Accuracy
- 25- Adaptation
- 26- Simplicity
- 27- Real Time Processing
- 28- Non Priori Knowledge of Noise
- 29- Zero Crossing Rate
- 30- Linear Prediction Error Energy
- 31- Time Duration
- 32- Periodicity Measure
- 33- Mel Frequency Channel Gain
- 34- Mel Frequency Cepstrum Coefitient
- 35- Multi State Transition diagram
- 36- Island of Reliable
- 37- Babble Noise
- 38- Maximum Information Point SBED
- 39- Sorting Filter
- 40- Periodicity Likelihood Measure
- 41- Pitch Syncronous Analisis
- 42- Normalized Cross Correlation
- 43- Bandpass filtering
- 44- Finite Impulse
- 45- Parks Mac Celean
- 46- Decimation
- 47- Right Context Dependent PM
- 48- Left Context Dependent PM
- 49- Time Frequency Energy
- 50- Fast Fourier Transform
- 51- Log of Bandpass Power
- 52- Smothened Log of Bandpass Power
- 53- Sorted Right Context Power
- 54- Sorsted Left Context Power
- 55- Low Power
- 56- High Power
- 57- Begin of MIP
- 58- Non Stationary Measure
- 59- Vowel
- 60- Consonant Vowel
- 61- Consonant Vowel Consonant
- 62- Inforamation Technology
- 63- Pink Noise
- 64- Office Noise
- 65- Telephone Ring

مراجع

- [1] J. C. Junqua, B. Mak, B. Reaves, "A Robust Algorihtm for Word Boundary Detection In The Presence of Noise ", IEEE Transaction On Speech And Audio Processing, Vol.2, No.3, July 1994.
- [2] C. T. Ling, J.Y. Lin, G. D. Wu, "A Robust Word Boundary Detection Algorothm For Variable Noise Level Environment In Cars", IEEE Trans. On Intelligent Transportation Systems, Vol.3, No.1, March 2002.
- [3] Q. Li, J. Zheng, A. Tsai, Q. Zhou, "Robust Endpoint Detection And Energy Normalization For Real Time Speech And Speaker Recognition" IEEE Trans. On Speech And Audio Processing, Vol.10, No.3, March 2002.
- [4] L. F. Lamel, L. R. Rabiner, A. E. Rosenberg, J. G. Wilpon, "An Improved Endpoint Detector For Isolated word Recognition"IEEE Trans. On Acoustics, Speech And Signal Processing, Vol. Assp -29, No.4, August 1981.
- [5] H. Ney, "An Optimization Algorithm For Determining The Endpoints Of Isolated Utterances" Proc. Of ICASSP-81, pp. 720-723,1981.
- [6] M. H. Savoij, "A Robust Algorithm For Accurate Endpointing Of Speech Signals" Speech Communication Vol.8, pp.46-60, 1989, North Holland, Elsevier Science Publishers.
- [7] C. Tsao, R. M. Gray, "An Endpoint Detector For LPC Speech Using Residual Error Look-Ahead For Vector Quantization Applications" Proc.Of ICASS-82, 1982, pp. 18b-701-4.
- [8] B. Reaves, "Comments On An Improved Endpoint Detector For Isolated Word Recognition" Corresp. Of IEEE Acoust. Speech, Signal Processing, Vol.39, pp.526-527, Feb. 1991.
- [9] S. E. B. Ghazale, K. Assleh, "A Robust Endpoint Detection Of Speech For Noisy Environments With Application To Automatic Speech Recognition" In Proc. Of IEEE ICASSP, IV – 3808-3811,2002.
- [10] M. Hamada, Y. Takizawa, T. Norimatsu, "A Noise Roboust Speech Recognition System," In Proc. Of ICSLP-90, pp.893-896, 1990.
- [11] R. Tucker, "Voice Activity Detection Using A Periodicity Measure" , IEEE Proceedings-1, Vol.139, No.4, August1992.
- [12] S. Tanyer, H. Ozer, "Voice Activity Detection In Nonstationary Qausian Noise" In Proc Of ICSLP-98, 1998.
- [13] F. Beritelli, S. Casale, A. Cavallaro, "A Robust Voice Activity Detector For Wireless Communications Using Soft Computing" IEEE Journal On Selected Area In Communications, Vol.16, No.9, Decmber 1998.
- [14] J. Sohn, N. S. Kim, W. Sung, "A Statistical Model Based Voice Activity Detection" IEEE Signal Processing Letters, Vol.6, No.1, January 1999.
- [15] S. G. Tanyer, H. Ozer, "Voice Activity Detection In Nonstationary Noise", IEEE Transction On Speech And Audio Processing, Vol.8, July 2000.
- [16] W. Hess. "Pitch Determination Of Speech Signals," New York, Springer, 1983.
- [17] Y. Medan, E. Yair, D.Chazan, "Super Resolution Pitch Dtermination Of Speech Signals" IEEE Trans. On Signal Processing, Vol. 39, No. 1, January 1991.
- [18] P. Veprek, M. S. Scordilis, "Analysis, Enhancement And Evaluation Of Five Pitch Determination Techniques" Elsevier Trans. On Speech Communimication Vol.37, Pp. 249-270, 2002.
- [19] A. V. Oppenheim, R. W. Schafer, "Discrete Time Sigmal Processing" Prectice Hall Publisher, 1989.
- [20] J. Pencak, D. Nelson, "The NP Speech Activity Detection Algorithm" IEEE Proc. On ICASSP, pp.138-384, 1995.