

ارائه روشی مبتنی بر نرم‌السازی اکوستیکی و خوشبندی برای بهبود بازشناسی گفتار کودکان

فارسی زبان

قمرناز تدین تبریزی^(۱)* سعید ستایشی^(۲)

(۱) دانشجوی دکتری مهندسی کامپیوتر - نرم افزار، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران ، گروه مهندسی کامپیوتر، تهران، ایران
 (۲) دانشیار، دانشگاه صنعتی امیرکبیر، گروه مهندسی هسته ای، تهران، ایران

چکیده بررسی کاربردهای بازشناسی گفتار نشان دهنده تفاوت‌های طیفی در سیگنال‌های گفتار کودکان می‌باشد. این تنوع، باعث ایجاد مشکلاتی در بازشناسی خودکار گفتار کودکان می‌شود. تجربه نشان داده در صورتی که از داده گفتار کودکان به عنوان ورودی در مدل‌های اکوستیکی استفاده شود که با گفتار بزرگسالان آموختن یافته‌اند، کارایی به اندازه قابل توجهی کاهش می‌یابد. به طور میانگین نرخ خطای کلمه برای بازشناسی گفتار کودکان دو تا چهار بار بیشتر از بزرگسالان است. میزان درستی بازشناسی گفتار در کودکان به عواملی مثل سن، جنسیت، فرکانس مبنای و قد بستگی دارد. در این مقاله برخی از روش‌های افزایش کارایی بازشناسی گفتار کودکان شامل هنجارسازی طول محدوده صوتی (VTLN)، آموختن تطبیقی گوینده (CMSLN) و هنجارسازی گوینده بر اساس رگرسیون خطی با بیشترین درست نمایی محدود شده (SAT) مطرح و روش VTLN برای بهبود کارایی بازشناسی گفتار کودکان فارسی زبان پیاده سازی شده است. نهایتاً روشی بر مبنای ترکیب روش‌های هنجارسازی و خوشبندی برای بازشناسی گفتار کودکان پیشنهاد شده است. با استفاده از خوشبندی گفتار ورودی و تخصیص آن به مدل مناسب، درستی بازشناسی به طور متوسط ۵۰٪ افزایش می‌یابد.

واژه‌های کلیدی بازشناسی گفتار کودکان، تبدیل صوت، مدل سازی تطبیقی، نرم‌السازی گوینده، خوشبندی گفتار.

*عهده دار مکاتبات

نشانی: مشهد، قاسم آباد، دانشکده فنی و مهندسی دانشگاه آزاد اسلامی واحد مشهد، گروه فناوری اطلاعات
 پست الکترونیکی: tadyon@mshdiau.ac.ir

تلفن: ۰۵۱۱-۶۶۲۲۷۸۹

ارائه روشی مبتنی بر نرم‌مال سازی اکوستیکی و خوشه بنای ...

تطبيق دادن یک شناسنده استفاده کردند. در این تجربه بدون تغییر مدل، از روش‌های انتقال بردار ویژگی استفاده شد [۴].

یکی از روش‌های افزایش کارایی این گونه سیستم‌ها استفاده از داده‌های گفتار کودکان برای آموزش و تطبيق با مدل‌های صوتی موجود می‌باشد. این در حالی است که جمع آوری گفتار کودکان نیز خود با مشکلات زیادی همراه است که از آن جمله می‌توان به مواردی مثل عدم همکاری و نداشتن توانایی کافی برای خواندن متن آماده شده اشاره کرد [۵]. از این رو تحقیقات، بیشتر به سمت تطبيق فن آوری بازشناسی گفتار بزرگسالان برای کاربرد در گفتار کودکان متوجه شده اند.

در این مقاله ابتدا ویژگی‌های اکوستیکی گفتار کودکان بررسی خواهند شد و سپس روش‌های پیشنهادی برای تطبيق شناسنده‌های گفتار برای استفاده کودکان مطرح و ارزیابی می‌شوند. یکی از مسائلی که به ویژه در بازشناسی گفتار کودکان اهمیت دارد، تنوع بسیار زیاد ویژگی‌های اکوستیکی و زبانی در سنین پایین است. به این جهت یک سیستم بازشناسی پیشنهاد شده که در آن دو مدل بر مبنای خوشه بنای واژگان آموزش می‌بینند و در مرحله باز شناسی نیز، کلمه ورودی بر مبنای HMM‌های خوشه ای که در آن قرار می‌گیرد بازشناسی می‌شود.

۲- ویژگی‌های فیزیکی و آوایی گفتار در کودکان
تأثیر سن گوینده بر درستی شناسنده‌های گفتار ابتدا توسط Wilpon و Jacobson مورد توجه قرار گرفت [۶]. بهترین کارایی در بازشناسی گفتار زمانی به دست می‌آید که برای هر گروه سنی مقدار داده کافی در مجموعه آموزش وجود داشته باشد، هرچند که این مقدار برای کودکان و افراد سالخورده بسیار پایین است. در جدول (۱) ضریب همبستگی بین برخی از ویژگی‌های کودکان و نرخ بازشناسی نشان داده شده

۱- مقدمه

مطالعات انجام شده در زمینه بازشناسی گفتار نشان میدهد که محققین این حوزه اغلب با گفتار بزرگسالان سروکار داشته و تحقیقات کمی در زمینه بازشناسی گفتار کودکان انجام داده اند. در این زمینه همواره بررسی کاربردهای محاوره ای برای ارتباط با کودکان مورد توجه بوده است [۱]. کودکان با کامپیوتر به گونه ای متفاوت از بزرگسالان ارتباط برقرار و صحبت می‌کنند و قطعاً سیستم‌های بازشناسی گفتاری که برای بزرگسالان طراحی شده اند نمی‌توانند در این رابطه به خوبی عمل کند. دلایل چندی وجود دارند که باعث کاهش کارایی سیستم‌های بازشناسی گفتار موجود برای کودکان شده است، از جمله تفاوت‌های فیزیکی، نحوه تلفظ و متفاوت بودن فرهنگ لغت کودکان. بنابراین زمانی که از مدل‌های گفتار بزرگسالان برای بازشناسی گفتار کودکان استفاده می‌شود، سطح کارایی به اندازه‌ای پایین است که باعث می‌شود این گونه سیستم‌ها غیرقابل استفاده شوند. اولین تحقیقات انجام شده در این زمینه، بیشتر متمرکز بر تطبيق فناوری بازشناسی گفتار بزرگسالان برای به کارگیری آن در بازشناسی گفتار کودکان بود. مسئله مهمی که در اینجا مورد توجه قرار گرفت، تفاوت خصوصیات آکوستیکی بین دو گروه بود. Das و همکارانش از روش‌های هنجارسازی طول Vocal tract length (VTLN) محدوده صوتی (normalization) در یک شناسنده گفتار بزرگسالان استفاده کردند تا سیستم را برای کاربری آن در محدوده کودکان آماده نمایند [۲]. Gustafson و همکارش نیز از شناسنده گفتاری استفاده کردند که در آن به لایه استخراج ویژگی‌ها دسترسی نبود و بنابراین نمی‌توانستند از VTLN استفاده کنند. در عوض، از روش‌های تبدیل صوت برای هنجارسازی سیگنال استفاده کردند [۳]. هردو روش باعث افزایش کارایی در بازشناسی گفتار شدند. Narayanan و همکارش از ترکیب روش‌های VTLN و تبدیل خطی پارامترها برای

- اکوستیکی و افزایش تنوع اکوستیکی، به طور چشمگیری کارایی بازشناسی را کاهش می‌دهند. این تفاوت‌ها را می‌توان به شکل زیر خلاصه کرد:
- با توجه به این که کودکان از محدوده صوتی (Vocal tract) کوتاهتر (فاصله بین تارهای صوتی تا لب‌ها) و دریچه صوتی (Vocal fold) کوچکتری برخوردارند، فرکانس مبنایی (Fundamental frequency) (F_0) و پهنهای باند سازه‌های آنها نسبت به بزرگسالان بالاتر است. این مسئله باعث می‌شود که فاصله زیادی بین همنواها (Harmonics) باشد و در نتیجه استخراج ویژگی‌های طیفی (Spectral) که یک مرحله اصلی در پردازش سیگنال است برای گفتار کودکان بسیار مشکل‌تر می‌باشد. به علاوه، در یک پهنهای باند سیگنال مشخص مثل باند ۴ kHz تلفنی، سازه‌های کمتری در طیف گفتار کودکان نسبت به بزرگسالان وجود دارد. بنابراین، نمونه برداری پراکنده از طیف و سازه‌های نسبتاً کمتر در یک پهنهای باند معین باعث ایجاد محدودیت‌های عمده در مقدار اطلاعات به دست آمده از صدای می‌شود.
 - متغیر بودن مقادیر سازه باعث می‌شود محدوده گروه‌های آوایی در کودکان فصل مشترک بزرگتری داشته باشند و بنابراین مسئله دسته بندی الگو مشکل‌تر می‌شود.
 - کودکان نسبت به بزرگسالان طنین صدای بالاتری دارند، طول بخش‌های آوایی آنها بیشتر است و گوناگونی طیف بیشتری دارند.
 - با توجه به موارد فوق، قطعاً سیستم‌های شناسایی گفتاری که برای بزرگسالان طراحی شده اند نمی‌توانند در بازشناسی گفتار کودکان به خوبی عمل کنند. بسیاری از سیستم‌های بازشناسی گفتار وقتی بر روی گفتار کودکان آزمایش می‌شوند موفق نبوده و مشاهده می‌شود که نرخ خطای نسبت به بزرگسالان حتی تا ۲۰٪ افزایش می‌یابد. یکی از روش‌های افزایش کارایی این گونه

است [۷].

جدول ۱ همبستگی بین برخی ویژگی‌های گوینده و نرخ خطای

کلمه [۷]

همبستگی	ویژگی
-۰/۵۱	سن
-۰/۴۹	قد
۰/۴۰	میانگین F2 (Hz)
۰/۳۶	میانگین F0 (Hz)
-۰/۰۵	جنسیت
۰/۰۵	میانگین F1 (Hz)

با بررسی جدول مشاهده می‌شود که عامل جنسیت کودک، ضریب همبستگی بسیار پایینی با دقت بازشناسی گفتار دارد بنابراین نیازی نیست که تفاوتی بین گفتار دختر و پسر در نظر گرفته شود. دلیل این مسئله، عدم تفاوت بین ویژگی‌های گفتار دختر و پسر تا حدود سن ۱۰ سالگی می‌باشد. بالا بودن همبستگی بین قد کودک و نرخ خطای نشان می‌دهد که استفاده از روش‌هایی مثل VTLN در بازشناسی گفتار کودکان می‌تواند مفید باشد. سن، با بسیاری از ویژگی‌های کودک مثل قد و زمان یادگیری صحبت رابطه مستقیم دارد و همچنین همبستگی بالایی با نرخ خطای کلمه دارد، لذا توجه به سن کودکان یک عامل کلیدی در هنجار سازی گوینده و بازشناسی گفتار می‌باشد. این عامل، دلیل اصلی به کارگیری روش خوش بندی در بازشناسی گفتار است که در این مقاله پیشنهاد شده است.

مطالعات در زمینه گفتار کودکان تفاوت‌هایی را در خصوصیات اکوستیکی گفتار مثل سازه‌ها (Formant)، طنین (Pitch) و تداوم صوت (Duration) نشان می‌دهد که این تفاوت‌ها وابسته به سن می‌باشند [۶، ۷]. دامنه وسیع تر پارامترهای

ارائه روشی مبتنی بر نرم‌مال سازی اکوستیکی و خوشه بنای ...

مختلف با استفاده از تبدیل‌های خاص گوینده است که با استفاده از MLLR در توزیع‌های خروجی HMM‌ها تخمین زده می‌شود [۹]. در این روش به جای تغییر در پارامترهای مدل، مشاهدات اکوستیکی هر گوینده برای آموزش و آزمایش تبدیل می‌شوند. یک مجموعه از مدل‌ها که کاملاً با داده غیر نرم‌مال آموزش دیده‌اند به عنوان مدل هسته درنظر گرفته می‌شوند و پارامترهای گویند این مدل‌ها به طور تکرار شونده با بکارگیری تبدیل‌های تخمین زده شده با استفاده از داده آموزش مجددًا تخمین زده می‌شوند. در مرحله بازناسی، پارامترهای انتقال مجددًا با توجه به مدل‌های استفاده شده در کدگشایی تخمین زده می‌شوند.

ب) CMLSN: یک روش هنگارسازی گوینده است که از انتقال بردارهای مشاهدات اکوستیکی با به کار گیری تبدیل MLLR خاص گوینده استفاده می‌کند. این انتقال با هدف کاهش عدم تطابق داده گویندگان با توجه به مجموعه‌ای از HMM‌های هدف انجام می‌شود که با مجموعه HMM‌هایی که برای بازناسی استفاده می‌شوند متفاوتند. این فرایند در هر دو مرحله آموزش و رمزگشایی انجام می‌شود [۱۰].

ج) VTLN: بدیهی است که طول محدوده صوتی در گویندگان متفاوت است. افرادی که طول محدوده صوتی آنها کوتاه‌تر است صدای زیرتری دارند و بر عکس. این تفاوت، باعث عدم تطابق بین آموزش و آزمایش شناسنده می‌شود و بنابراین کارایی بازناسی کاهش می‌یابد. در طول مرحله استخراج ویژگی می‌توان این تفاوت‌ها را کاهش داد. به این فرایند، کاهش محدوده صوتی گفته می‌شود. اساس این روش گسترش یک لوله (tube) به اندازه فاکتور α است فرکانس طیف را تغییر می‌دهد. مثلاً با دو برابر کردن طول لوله، تشدید (resonance) صدا از ۱۰۰ Hz به ۲۰۰ Hz تغییر می‌کند. همچنین برای این منظور می‌توان مقیاس بردار فرکانس را تغییر داد. VTLN تغییر مقیاس بردار فرکانس به صورت خطی، دوخطی یا غیرخطی می‌باشد. در این

سیستم‌ها استفاده از داده‌های گفتار کودکان برای آموزش و تطبیق با مدل‌های صوتی موجود می‌باشد که با توجه به مواردی که در بخش قبل ذکر شد با مشکلات زیادی همراه است. از این رو تحقیقات، بیشتر به سمت تطبیق فن آوری بازناسی گفتار بزرگسالان و یا استفاده از داده نسبتاً محدود برای کاربرد در گفتار کودکان متمایل شده‌اند.

۳- روش‌های افزایش کارایی بازناسی گفتار در کودکان

استفاده از داده آموزش بیشتر در سیستم‌های بازناسی گفتار متداول که هزینه و زمان زیادی صرف می‌کند، تنها راه حل برای افزایش کارایی در سیستم‌های بازناسی گفتار کودکان نمی‌باشد، بلکه به دلیل وجود تفاوت‌های عمده موجود در گفتار کودکان، استفاده از روش‌های تبدیل صوت و تطبیق شناسنده برای کاربرد در گفتار کودکان پیشنهاد می‌شوند. که در ادامه مورد بررسی قرار خواهند گرفت.

۳-۱- مدل سازی اکوستیکی قابل تطبیق با گوینده
 یکی از روش‌های موفق در افزایش نرخ بازناسی گفتار برای بزرگسالان و کودکان، مدل سازی قابل تطبیق با گوینده می‌باشد که هدف از آن کاهش تفاوت‌های اکوستیکی است که در اثر ویژگی‌های متفاوت گویندگان در مراحل آموزش و آزمایش ایجاد می‌شود. از جمله روش‌هایی که بر این اساس عمل می‌کند می‌توان به VTLN، آموزش قابل تطبیق با گوینده (SAT) (Speaker Adaptive Training) و هنگارسازی گوینده بر اساس رگرسیون خطی با بیشترین درست نمایی (Maximum Likelihood Linear Regression) (MLLR) محدود شده (Constrained MLLR based) (CMLSN) (Speaker Normalization) اشاره کرد:
الف: هدف از روش آموزش قابل تطبیق با گوینده، تنظیم و کاهش تنوع آکوستیکی بین گویندگان

مقیاس فرکاس به صورت بروون خطی و نه بلادرنگ انجام می‌شود. در ادامه الگوریتم مورد استفاده ارائه می‌شود [۱۱]. تغییر مقیاس محور فرکانس با بهینه سازی منحنی مل (Mel-curve) انجام می‌شود که فیلتربانک را برای محاسبه ضرایب MFCC تعیین می‌کند.

منحنی مل با رابطه زیر داده می‌شود:

$$\text{mel}(f) = 1125 \ln\left(1 + \frac{f}{700}\right) \quad (1)$$

به منظور تطبیق منحنی با ویژگی‌های داده، n نقطه نمونه $(f_i, p(f_i))$ تعیین می‌شوند که به طور یکنواخت در مقیاس مل قرار گرفته‌اند:

$$f_i = \text{mel}^{-1}\left((i-1) \cdot \frac{f_{\max}}{n-1}\right), i \in 1, \dots, n \quad (2)$$

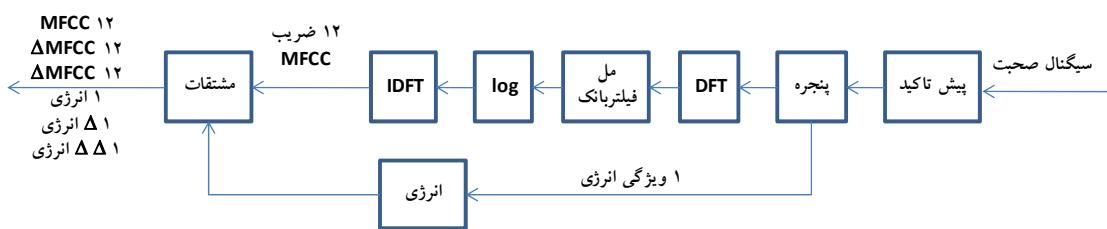
وابسته به فرکانس نمونه برداری است و F_{\max} در نظر گرفته شده است. مقداردهی اولیه نقاط نمونه با منحنی مل داده شده است:

$$p(f_i) = \text{mel}(f_i), i \in 1, \dots, n \quad (3)$$

منحنی بهینه شده $\text{opt}(f)$ شامل نقاط نمونه می‌باشد. الگوریتم بهینه سازی به طور تکرارشونده مقادیر $p(f_i)$ را تغییر می‌دهد.

مقاله از یک روش تغییر مقیاس استفاده شده تا فیلتربانک بهینه برای استخراج خطی ویژگی‌های اکوستیکی از گفتار کودکان تعیین شود. در مرحله بعد با استفاده از هنجارسازی نرخ گفتار کودکان، کارایی افزایش می‌یابد. هنجارسازی را می‌توان با استفاده از تطبیق طیف در مرحله استخراج ویژگی‌ها با تغییر فضای پهنهای فیلترهای مقیاس مل انجام داد. VTLN هم در طی مرحله آموزش و هم در طی فرایند بازشناسی قابل اجرا است. در مرحله آموزش، توابع تطبیق فرکانس وابسته به گوینده برای ایجاد مدل‌های اکوستیکی نرم‌الله اجرا می‌شوند. در مرحله بازشناسی از یک تابع تطبیق وابسته به گفتار استفاده می‌شود که در زمان محاسبه بردارهای ویژگی به کار می‌رود. برای این منظور نیاز به کنترل کامل بر روایهای آموزش و رمز گشایی می‌باشد.

VTLN بر اساس این فرضیه عمل می‌کند که بخش قابل توجهی از تفاوت‌های ویژگی‌های گویندگان را می‌توان با استفاده از تغییر خطی مقیاس محور فرکانس کاهش داد. در بسیاری از کاربردها لازم است تطبیق به گوینده جاری بسیار سریع انجام شود و بنابراین عملیات محاسباتی و جستجو برای یافتن تغییر مقیاس فرکانس خطی هزینه زیادی خواهد داشت. در این مقاله، تغییر مقیاس یک بار برای کل گروه گویندگان تعیین می‌شود و بیشتر تاکید بر تفاوت بین صدای اطفال و بزرگسالان است و نه گویندگان خاص. بنابراین تعیین



شکل ۱ استخراج دنباله بردار ویژگی MFCC، ۳۹ بعدی با استفاده از شکل موج دیجیتالی شده کوانتیزه

ارائه روشی مبتنی بر نرم‌السازی اکوستیکی و خوشه بندی ...

هدف بهینه سازی، به حداقل رساندن نرخ بازشناسی می‌باشد. خلاصه این روال در الگوریتم (۱) ذکر شده است.

الگوریتم (۱): تطبیق پارامترها

f_i و $p(f_i)$ با توجه به معادلات (۱) و (۲) مقداردهی می‌شوند.

با توجه به هدف بهینه سازی زیر، مقدار $p(f_i)$ به طور تکرارشونده تطبیق می‌باید.

الف) منحنی $opt(f)$ برای نقاط $(f_i, p(f_i))$ محاسبه می‌شوند

ب) فیلتربانک با توجه به $opt(f)$ تعیین می‌شود.

ج) ویژگی‌های اکوستیکی با استفاده از فیلتربانک جدید استخراج می‌شوند.

د) نرخ بازشناسی محاسبه می‌شود.

ه) روال تکرار می‌شود.

۳- مقدار $opt(f)$ برگردانده می‌شود.

مزیت الگوریتم این است که تعداد پارامترهایی که باید بهینه شوند را می‌توان مستقل از تعداد فیلترهایی که در استخراج ویژگی به کار می‌روند انتخاب کرد.

۴- پیاده سازی و نتایج

در حال حاضر، متداول ترین روش طراحی سیستم‌های بازشناسی گفتار، بر مبنای مدل مخفی مارکوف (HMM) می‌باشد [۱۳]. در این مقاله از ابزار HTK برای پیاده سازی این سیستم استفاده شده است [۱۴].

اولین مرحله در طراحی یک سیستم بازشناسی گفتار، فاز استخراج ویژگی است که در این مقاله از ضرایب MFCC (Mel Frequency Cepstral Coefficients) استفاده شده است. مراحل ایجاد مجموعه ویژگی‌ها در شکل (۱) نشان داده شده است که نهایتاً شامل ۱۲ ضریب کپسٹرال و یک انرژی به همراه مشتق‌های اول و دوم آنها می‌باشد.

برای بررسی نتایج حاصله از طراحی شناسنده، سیستم‌های زیر پیاده سازی شدند [۱۵، ۱۶]:

- ۱- مدل آموزش یافته با استفاده از گفتار بزرگسالان.
- ۲- مدل آموزش یافته با استفاده از گفتار کودکان.
- ۳- سیستمی که با استفاده از گفتار کودکان آموزش یافته است و در آن از روش‌های تطبیق استفاده شده است.
- ۴- سیستم آموزش یافته با گفتار بزرگسالان که در آن از روش‌های تطبیق استفاده شده است. در این بخش دو زیر سیستم نیز طراحی شد که یکی بر اساس گفتار بزرگسالان زن و دیگری بزرگسالان مرد می‌باشد.

۴-۲- روش‌های تبدیل صوت

در سیستم‌های بازشناسی گفتار در صورتی که دسترسی به لایه ویژگی‌ها امکان پذیر نباشد امکان استفاده از روش VTLN وجود ندارد. در این صورت می‌توان روش‌های تبدیل صوت را برای هنجارسازی سیگنال به کار برد [۳]. در این روش، تبدیل‌ها بر روی اصواتی که در ۱۶ kHz نمونه برداری شده انجام می‌گیرد و سپس سیگنال پیش از ورود به شناسنده که از مدل‌های اکوستیکی با پهنای باند تلفنی استفاده می‌کند در ۸ kHz نمونه برداری می‌شود. با توجه به این فرکانس صدای کودکان بالاتر از بزرگسالان است، امکان به کارگیری برخی از اطلاعات طیفی ایجاد می‌شود که در صورت استفاده از روش ضبط در پهنای باریک از بین می‌رفتند. یکی از روش‌های متداول در ای زمینه، الگوریتم TD-

نتایج بازشناسی گفتار برای دو مدل آکوستیکی نشان داده شده است. همانگونه که انتظار می‌رود، کارایی برای شرایطی که داده‌های آموزش و آزمایش با هم منطبق نیستند پایین‌تر است.

نکته دیگری که مورد بررسی قرار گرفته است جنسیت داده آموزش می‌باشد. درستی شناسنده بر مبنای سن با چهار مدل در جدول (۲) نشان داده شده است.



شکل ۲ کارایی شناسنده کلمه با دو مدل آکوستیکی

با بررسی میانگین درستی شناسنده مشاهده می‌شود که به طور کلی مدل کودکان بالاترین درستی را دارد، در حالیکه درستی مدل بزرگسالان و بزرگسالان زن حدود ۲۹٪ و ۱۱٪ کمتر از مدل مبنا (کودکان) می‌باشد و مدل بزرگسالان مرد کمترین کارایی ۵۶٪ کمتر از مدل مبنا) را دارد. این نتایج نشان می‌دهد که ویژگی‌هایی اکوستیکی گفتار کودکان به گفتار بزرگسالان زن شباهت بیشتری دارد.

۴-۱-دادگان مورد استفاده

استفاده از واژگان مناسب در نتایج سیستم‌های بازشناسی گفتار تأثیر زیادی دارد. پایگاه داده مورد استفاده در این پایان نامه از دو بخش تشکیل شده است، پایگاه داده گفتار بزرگسالان و کودکان. داده بزرگسالان برای آموزش شناسنده بزرگسالان و همچنین در ارزیابی نتایج به عنوان مرجع به کار رفته است. داده کودکان در آموزش، تطبیق و ارزیابی شناسنده به کار رفته است.

برای پایگاه داده بزرگسالان از داده گفتار گستته موجود در پایگاه داده فارس دات استفاده شده است که در اتاق اکوستیک آزمایشگاه زبان شناسی دانشگاه تهران تهیه شده است.

متأسفانه پایگاه داده استانداردی برای گفتار کودکان فارسی زبان وجود ندارد. واژگان به کاررفته در این پایان نامه از داده گفتار ۵۰ کودک سالیان ۲ تا ۱۰ سال در محیطی با نویز کم جمع آوری شده است. به دلیل مشکلات موجود در انتقال کودکان به محل ضبط صدا، برای افزایش داده گفتار، هر کودک دنباله‌ای از ارقام را ۲۰ مرتبه (بدون در نظر گرفتن حالت‌های غیرقابل قبول) تکرار کرده است.

برای بررسی نقش هر یک از عوامل، آزمایش‌های متفاوتی اجرا و نتایج آنها به شرح زیر مورد بررسی قرار گرفت.

۴-۲-نقش داده آموزش

در ابتدا، شناسنده با استفاده از داده بزرگسالان آموزش یافته و با یک بار با استفاده از داده بزرگسالان و یک بار با استفاده از داده کودکان نیز آزمایش شد. در شکل (۲)

جدول ۲ تغییرات درستی شناسنده آموزش داده شده با گروه‌های سنی مختلف

سن	بزرگسالان	بزرگسالان زن	بزرگسالان مرد	کودکان
میانگین	۴۸.۸۸	۶۱.۷۳	۳۰.۵۷	۶۹.۲۸
تفاوت دقیق با مدل مبنا (کودکان)	٪۲۹	٪۱۱	٪۵۶	٪۰

ارائه روشی مبتنی بر نرم‌مال سازی اکوستیکی و خوشه بنای ...

کودکان مختلف در بیان کلمات می‌باشد. در صورتی که ضریب همبستگی بین سن و دقت شناسنده محاسبه شود، عدد 0.86 به دست می‌آید که نشان دهنده تأثیر بسیار قابل توجه سن در دقت بازشناسی گفتار است.

۴-۴- نقش جنسیت

برای بررسی این که آیا جنسیت کودکان نقش قابل توجهی در نتایج بازشناسی دارد یا خیر، دقت برای هر جنس به طور جداگانه به دست آمده که نتایج آن در شکل (۵) دیده می‌شود. این که دقت بازشناسی گفتار کودکان پسر در شناسنده‌های بزرگسال بالاتر است به این دلیل می‌باشد که تفاوت‌های اکوستیکی گفتار کودکان دختر نسبت به پسر بیشتر می‌باشد. از طرفی معمولاً کودکان دختر واضح‌تر صحبت می‌کنند، بنابراین دقت بازشناسی شناسنده کودکان بر گفتار کودکان دختر بالاتر است. البته همانطور که مشاهده می‌شود این تفاوت‌ها ناجیز می‌باشد.



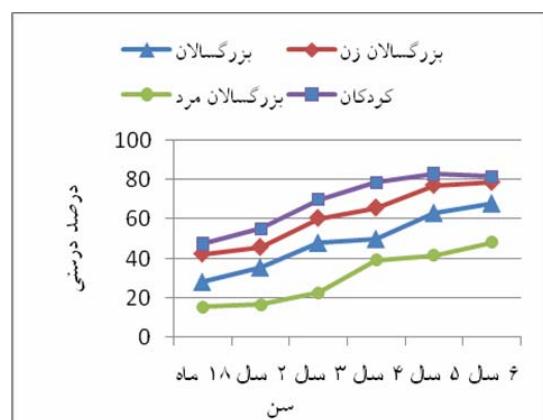
شکل ۵ درستی شناسنده برای کودکان دختر و پسر

۴-۵- کاربرد روش‌های تبدیل صوت در بازشناسی گفتار

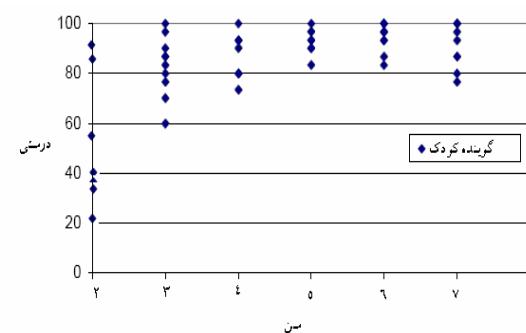
در این پایان نامه از اجرای PSOLA در نرم افزار PRAAT برای تغییر در طول گفتار کودکان استفاده شده است. جدول (۳) نتایج بازشناسی گفتار را در یک آزمایش نمونه که برای بازشناسی گفتار کودکان بین ۲ تا ۱۰ سال انجام گرفته نشان می‌دهد نرخ خطای پرس و

۴-۳- نقش سن

درستی شناسنده با چهار مدل بدون استفاده از هنجارسازی در شکل (۳) مشاهده می‌شود. نکته ای که در این نتایج قابل توجه است، تغییرات درستی شناسنده کودکان با سن می‌باشد. دقت بازشناسی در میانه این بازه (۳ تا ۵ سال) بالاتر و در کرانه‌ها (زیر ۲ سال و حدود ۶ سال) پایین‌تر می‌باشد. یک دلیل عمدۀ کاهش کارایی در حدود سن ۶ سال، از دست دادن دندان‌های شیری و تلفظ متفاوت کلمات می‌باشد.



شکل ۳ دقت بازشناسی گفتار کودکان به صورت تابعی از سن با چهار مدل مختلف



شکل ۴ درصد درستی بازشناسی برای هر گوینده

در شکل (۴) نمودار دقت بازشناسی برای هر کودک نشان داده شده که تفاوت قابل توجهی را در میزان بازشناسی برای هر کودک در یک گروه سنی خاص نشان می‌دهد که به دلیل قابلیت‌های فردی

با استفاده از روش‌های تطبیق مدل و VTLN می‌توان کارایی مدل‌های بزرگسالان را برای استفاده گفتار کودکان افزایش داد، هرچند که استفاده از داده آموزش کودکان نتیجه بهتری دارد.



شکل ۶ درستی کلمه با توجه با افزایش سن قبل و بعد از هنجارسازی

در شکل (۶) دقیق بازناسی با استفاده از دو مدل کودکان و بزرگسالان قبل و بعد از هنجارسازی که روش‌های آن در بخش‌های قبل بررسی شدند، مشاهده می‌شود. در اینجا فقط از روش VTLN استفاده شده است.

۴-۷- کاربرد خوش بندی برای افزایش کارایی
یکی از نکاتی که در نحوه صحبت کودکان به چشم می‌خورد تنوع در نحوه بیان صدایها و کلمات توسط آنها می‌باشد. برخلاف بزرگسالان، تفاوت بین گفتار بین کودکان مختلف حتی در بازه‌های سنی محدود بسیار گسترده است. نتایج تجربی نشان می‌دهند که تنوع در ویژگی‌های آکوستیکی گفتار کودکان را نمی‌توان به سادگی با مدل‌های آکوستیکی مستقل از سن نشان داد. از این جهت، در این بخش طراحی و پیاده سازی سیستمی که قادر باشد شناسنده مناسب را وابسته به صدای گوینده انتخاب کند پیشنهاد می‌شود. برای رسیدن به این هدف، از خوش بندی گفتار کودکان برای نمایش دقیق تر تنوع در ویژگی‌های آکوستیکی کودکان،

جو حدود ۴۵٪ کاهش یافته است. برای مشخص شدن این مسئله که آیا روش برای کودکان کم سن ترتیبی متفاوتی دارد یا خیر، داده‌ها به دو گروه سنی ۲-۶ سال و ۶-۱۰ سال تقسیم شده است.

جدول ۳ نرخ خطای کلمه به درصد برای دو گروه سنی

روش تبدیل	۶-۱۰ سال	۶-۲ سال
۱۴/۷	۵۳/۲	-
۹/۳	۳۹/۹	PSOLA

۴-۶- نتایج تجربی حاصل از اجرای VTLN
در جدول (۴) نتایج به دست آمده از بازناسی گفتار کودکان با استفاده از داده آموزش کودکان، بزرگسالان و ترکیبی از هردو برای مدل مخفی مارکوف (HMM) قبل و بعد از هنجارسازی نشان داده شده است.

جدول ۴ نرخ خطای بازناسی ارقام برای گویندگان کودک قبل و بعد از هنجارسازی

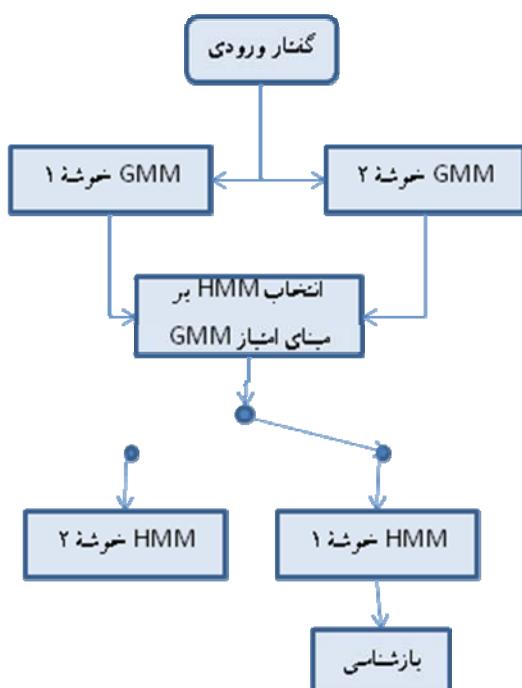
تغییر	بعد از هنجارسازی	قبل از هنجارسازی	
کارایی			HMM بزرگسالان
%۱۴	۵۵,۵۸	۴۸,۸۸	
%۲۰	۸۳,۱۳	۶۹,۲۸	HMM کودکان

در این مدل، ترکیبی از روش‌های VTLN تبدیل خطی پارامترها برای تطبیق دادن شناسنده ارقام به کار رفته است. بعد از اجرای فرایند هنجارسازی گوینده، نرخ درستی بازناسی برای کودکان در سنین بالاتر (حدود ۹ سال) قابل مقایسه با بزرگسالان است، هرچند که برای سنین پایین تر هنوز هم کارایی مطلوب به دست نمی‌آید. استفاده از روش‌های تنظیم فرکانس برای هنجارسازی گفتار کودکان قبل از آموزش مدل‌های آکوستیکی نرخ خطای بازناسی را تا ۵۵٪ کاهش می‌دهد.

ارائه روشی مبتنی بر نرم‌مال سازی اکوستیکی و خوشه بندی ...

و) با تکرار روال فوق برای n داده آموزش، n بردار نرم‌مال شده به دست می‌آید.

ز) از روال خوشه بندی براساس Kmeans برای ایجاد ۳ خوشه مورد نظر استفاده می‌شود.



شکل ۸ بازشناسی مبتنی بر خوشه بندی

در این مرحله، دو مدل اکوستیکی برای هر خوشه آموزش داده شده اند. با توجه به محدود بودن داده آموزش برای هر خوشه، از مدل کودکان مستقل از سن استفاده شده است که با استفاده از روش‌های تطبیق که در بخش‌های قبل به آنها اشاره شد، برای هر خوشه تطبیق یافته اند. مدل ترکیبی گوسین (GMM) بیشترین درست نمایی (MLE) با استفاده از تخمین Maximum Likelihood (MLE) (Estimation) با استفاده از داده‌های گفتار هر خوشه آموزش یافته است. در مرحله بازشناسی، هر گفتار ورودی به خوشه‌ای که GMM آن بالاترین تطبیق را با گفتار ورودی دارد مرتبط می‌شود و با استفاده از

و همچنین افزایش کارایی به خصوص در سنین پایین تر استفاده شده است. تعداد خوشه‌ها ثابت و برابر ۲ درنظر گرفته شده است ($\{2\}$ تا 4 سال)، $\{5\}$ تا 6 سال). بنابراین به جای استفاده از یک شناسنده، از دو شناسنده استفاده می‌شود که براساس نتیجه حاصل از خوشه بندی می‌توان برای بازشناسی هر وردی، مناسب ترین مدل را انتخاب نمود. این روش قابل تعمیم به k مدل نیز می‌باشد.

در مرحله خوشه بندی که در شکل (۷) نشان داده شده است، به صورت زیر عمل شده است:

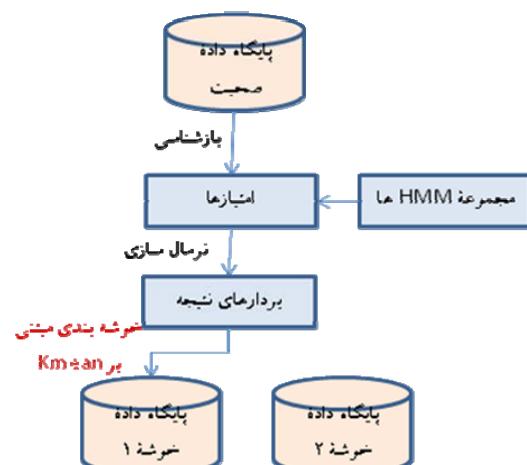
(الف) HMM ها برای هر سن با استفاده از داده همان بازه سنی آموزش دیده شده اند.

(ب) یک HMM بر اساس داده بزرگسالان مستقل از جنسیت ایجاد شده است.

(ج) روال خوشه بندی بر روی هر واژه در پایگاه داده اجرا شده است که نشان دهنده گوناگونی در ویژگی‌های گفتاری بین گویندگان می‌باشد. به ویژه این که کودکان برخی کلمات را کاملاً واضح و برخی را گنگ بیان می‌کنند.

(د) HMM ها براساس هر واژه پایگاه داده آموزش، یک مقدار امتیاز تولید می‌کنند.

(ه) خروجی امتیازها به صورت یک بردار می‌باشد که با توجه به مقدار امتیاز حداکثر، نرم‌مال می‌شوند.



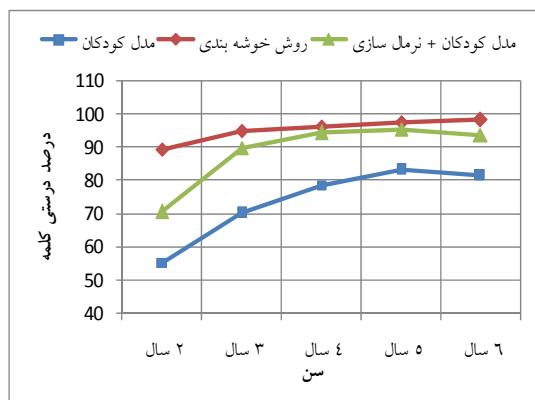
شکل ۷ اجزاء سیستم پیشنهادی

قابلیت‌های گفتاری کودکان می‌توان از مدل‌های گفتار بزرگسالان استفاده نمود.

۵- نتیجه‌گیری

گفتار کودکان از نظر خصوصیات اکوستیکی و زبانی با بزرگسالان متفاوت است. تغییرات در کودکان به خصوص رشد محدوده صوتی باعث ایجاد تنوع در پارامترهای طیفی سیگنال گفتار کودکان می‌شود. این موارد باعث بروز مشکلاتی در بازشناسی خودکار گفتار و افزایش نرخ خطای شود. در این مقاله، چندین مدل بر مبنای واژگان گروههای سنی مختلف طراحی و نتایج آنها مقایسه شد. استفاده از مدل‌های مبتنی بر گفتار بزرگسالان، با توجه به کارایی بسیار پایین، عملاً غیر ممکن و ناکارامد است که با استفاده از روش‌های هنجارسازی و تطبیق گفتار می‌توان این کارایی را تا حدی افزایش داد. باید توجه داشت که خصوصیات گفتاری کودکان بسیار با بزرگسالان متفاوت و دامنه تغییرات آنها وسیع تر است، بنابراین لازم است روش‌هایی برای تطبیق و هنجارسازی گفتار کودکان به کار روند. با توجه به این که عمدۀ تفاوت کودکان به لحاظ خصوصیات فیزیکی و درنتیجه اندازه تارهای صوتی و محدوده صوتی آنها می‌باشد، استفاده از روش هنجارسازی محدوده صوتی پیشنهاد گردید. همچنین از روش‌های تغییر در نرخ گفتار برای هنجارسازی گفتار ورودی استفاده شد. در نهایت با توجه به تنوع وسیع گفتار کودکان با یکدیگر و همچنین با بزرگسالان استفاده از یک مدل مبتنی بر خوش‌بندی گفتار پیشنهاد شد. در این مدل، گفتار کودکان به دو خوش‌بندی بر سن تقسیم شد و دو شناسنده بر مبنای این دو خوش‌بندی طراحی شد. با دریافت هر ورودی، خوش‌بندی مناسب انتخاب و بازشناسی براساس آن انجام می‌گیرد. با استفاده از این روش، دقت بازشناسی تا ۵۰٪ افزایش یافت.

HMM‌های همان خوش‌بندی بازشناسی می‌شود (شکل (۸)). همانطور که مشاهده می‌شود، استفاده از روش خوش‌بندی علیرغم افزایش پیچیدگی سیستم، کارایی شناسنده را افزایش می‌دهد. دلیل این امر وابسته بودن گفتار به محدوده سنی گوینده به ویژه در سنین پایین می‌باشد. بنابراین با طراحی مدل‌های وابسته به سن یا ویژگی‌های آوازی میتوان بازشناسی هر کلمه را با استفاده از نزدیکترین مدل به آن که توسط خوش‌بندی تعیین می‌شود انجام داد. با افزایش تعداد خوش‌بندی پیچیدگی سیستم و همچنین کارایی افزایش می‌یابد. در این مقاله براساس نتایج تجربی و آزمایش‌های انجام گرفته، دو خوش‌بندی پیش‌بینی شده است. نکته قابل توجه در این روش این است که در مرحله بازشناسی بدون توجه به سن گوینده، ورودی به نزدیکترین خوش‌بندی تخصیص می‌یابد. بنابراین کودکانی که سن بالاتری دارند ولی هنوز در بیان کلمات دچار مشکل هستند در خوش‌بندی اول قرار می‌گیرند و به این ترتیب، دقت بازشناسی افزایش می‌یابد.



شکل ۹ دقت بازشناسی مدل مبتنی بر خوش‌بندی

نتایج بازشناسی در شکل (۹) نشان داده شده‌اند. در این محدوده سنی، جنسیت گوینده تأثیری در نرخ بازشناسی ندارد، هرچند که با افزایش سن، ویژگی‌های اکوستیکی وابسته به جنسیت آشکارتر خواهد شد. در سنین بالاتر با توجه به افزایش

ارائه روشی مبتنی بر نرم‌مال سازی اکوستیکی و خوشه بنای ...

ج) در حوزه سرگرمی: ایجاد بازی‌هایی که هم‌زمان با ایجاد سرگرمی، بعد آموزشی و فرهنگی در آنها در نظر گرفته شده باشد.

در انتهای، مواردی که می‌توانند به عنوان زمینه ای برای ادامه پژوهش و تکمیل بحث انتخاب شوند به شرح زیر پیشنهاد می‌گردد:

الف) بسط محدوده سنی و ایجاد سیستم‌های هوشمند که قادر به بازشناسی آواها و اصوات کودکان از زمان آغاز به تکلم باشد.

ب) ایجاد سیستم بازشناسی کلمات پیوسته.

ج) افزایش تحمل نویز: با توجه به این که جمع آوری داده گفتار کودکان و ضبط صدای کنترل شده در محیط بدون نویز بسیار مشکل می‌باشد، بهتر است جمع آوری داده در محیط‌های معمول مثل کودکستان و مدرسه انجام شود.

ادامه این تحقیقات می‌تواند منشاء تحولی فراگیر در عرصه‌های روان‌شناسی، آموزشی و کامپیوتر قرار گیرد که برخی از آنها به شرح زیر می‌باشد:

الف) در حوزه آموزشی: با توجه به علاقه‌ای که کودکان به استفاده از سیستم‌های کامپیوتری نشان می‌دهند ایجاد رابطه‌ای نرم افزاری که توجه کودکان را جلب کند به عنوان ابزار بسیار مناسبی برای ابزارهای کمک آموزشی مانند آموزش زبان‌های خارجی، به کار می‌رود. متأسفانه از رهاردهای زندگی ماشینی امروزه، گرفتاری‌های والدین و نبودن وقت کافی برای ارتباط با کودکان می‌باشد. با استفاده از ابزارهای آموزشی می‌توان تا حد کمی این خلا را جبران نمود هرچند که در بعد روان‌شناسی هنوز مشکلات بسیاری باقی خواهد ماند.

ب) در حوزه پزشکی: ایجاد ابزارهای مکانیزه تعیین نارسایی‌های گفتاری و شنوایی

۶- مراجع

1. M. Gerosa, D. Giuliani and F. Brugnara, "Speaker adaptive acoustic modeling with mixture of adult and children's speech", In proceedings of the european conference on speech communication and technology [INTERSPEECH2005], Lisbon, Portugal, pp. 2193-2196, 2005.
2. S. Das, D. Nix, M. Picheny, "Improvements in children's speech recognition performance". Proceedings of the 1998 IEEE International Conference on Acoustics, Speech, and Signal Processing, Volume:1 , 12-15. pp. 433 – 436, May 1998.
3. J.Gustafson and K. Sjölander, "Voice transformations for improving children's speech recognition in a publicly available dialogue system", In the Proceedings of the International Conference on Spoken Language Processing, pp 297 – 300, 2002.
4. S. Narayanan and A. Potamianos, "Creating conversational interfaces for children", IEEE Transactions on speech and audio processing, Vol. 10, No. 2, February 2002.
5. M. Blomberg and D. Elenius, "Collection and recognition of children's speech in the PF-Star project", Ume University, department of philosophy and linguistics, PHONUM 9, 81-84, 2003.

6. J.G. Wilpon, C.N. Jacobsen, "A study of speech recognition for children and the elderly", In proceedings: ICASSP-96. IEEE international conference on acoustics, speech, and signal processing, vol. 1, 3527-10 May 1996.
7. D. Elenius and M. Blomberg, "Adaptation and normalization experiments in speech recognition for 4 to 8 year old children" Interspeech, Portugal, September 2005.
8. S. Lee, A. Potamianos and S. Narayanan, "Acoustics of children's speech: Developmental changes of temporal and spectral parameters", Journal of Acoust. Soc. Amer., vol. 105, no. 3, pp. 1455–1468, March 1999.
9. G. Stemmer, C. Hacker, S. Steidl and E. N'oth, "Acoustic Normalization of Children's Speech", In EUROSPEECH, Geneva , Switzerland , pp. 1313-1316, 2003.
10. Giuliani, D., Gerosa, M. and Brugnara, F. "Speaker Normalization through Constrained MLLR Based Transforms" in Proc. of INTERSPEECH/ICSLP, Jeju Island, Korea, Oct. 2004, pp. 2893–2897.
11. G. Stemmer, C. Hacker, S. Steidl, and E. N'oth, "Acoustic Normalization of Children's Speech", In EUROSPEECH, Geneva , Switzerland , pp. 1313-1316, 2003.
12. J .Cabral and L. Oliveira, "Pitch-Synchronous Time-Scaling for Prosodic and Voice Quality Transformations", Interspeech ,Lisbon, Portugal, September 2005.
13. A. Ogawa and S. Takahashi, "Children's Speech Recognition Based on Clustering Techniques." NTT Cyber Space Laboratories, 3 (12), 75-81, 2005.
14. S. Young, "The HTK Book", Revised for HTK Version 3.4, Cambridge University Engineering Department, Dec 2006.
15. G. Tadayon Tabrizi, S. Setayeshi and M. Molavi, "HMM-based recognition and adaptation of Persian children's speech". submitted to: ELEX Journal, 2009.
16. G. Tadayon Tabrizi, S. Setayeshi and M. Molavi, "Applying acoustic normalization to improve recognition of children's speech", Proc. 16th Iranian conference on electrical engineering, May 2008 (In Persian).