



نشر نویسه پارس



مجموعه مقالات سومین همایش ملی

زبان‌شناسی و سوره‌ای

به کوشش: آزاده میرزائی

مجموعه مقالات سومین همایش ملی



زبان‌شناسی پیکره‌ای

به کوشش

دکتر آزاده میرزائی

(عضو هیئت علمی دانشگاه علامه طباطبائی)



سرنشانه	همایش ملی زبان‌شناسی بیکره‌ای (سومین : ۱۳۹۸ : تهران)
عنوان و نام پدیدآور	مجموعه مقالات سومین همایش ملی زبان‌شناسی بیکره‌ای/به کوشش آزاده میرزایی ؛ برگزارکننده انجمن زبان‌شناسی ایران . با همکاری پژوهشگاه علوم انسانی و مطالعات فرهنگی ، پایگاه استنادی علوم جهان اسلام (ISC) ، نشر نوبه پاریس .
مشخصات نشر	تهران : نشر نوبه پاریس ، ۱۳۹۸ .
مشخصات ظاهری	۳۲۷ ص : مصور ، جدول ، نمودار .
شابک	۳ - ۲۲ - ۹۷۸ - ۶۲۲ - ۹۶۴۹
وضعیت فهرست نویسی	فیا
موضوع	زبان‌شناسی بیکره‌ای -- کنگره‌ها
موضوع	Corpus (Linguistics) -- Congresses
موضوع	زبان‌شناسی -- ایران -- کنگره‌ها
موضوع	Linguistics -- Iran -- Congresses
شناخه افزوده	میرزایی ، آزاده ، ۱۳۵۸ - . گردآورنده .
شناخه افزوده	انجمن زبان‌شناسی ایران .
رده بندی کنگره	۱۳۹۸ / ۳۲۸ / P۱۲۸
رده بندی دیویی	۱۸۸ / ۱۰
شماره کتابشناسی ملی	۵۱۳۶۵۱



تشر نویسه پارسیه
Neveesh Parsi Publishing

تهران، صندوق پستی ۱۶۷۶۵-۱۳۷۹

تلفن: ۷۷۰۵۳۲۴۶

فروشگاه: ۶۶۴۶۱۰۰۷

سامانه پیام کوتاه: ۳۰۰۰۴۵۴۵۴۱۴۲

وبگاه نشر نویسه پارسی:

www.neveesh.com



انجمن زبان شناسی ایران

تهران، بزرگراه چمران، پل مدیریت، خیابان علامه

طباطبایی جنوبی، دانشکده ادبیات فارسی و

زبان‌های خارجی دانشگاه علامه طباطبایی. طبقه

اول، اتاق ۱۱۷، صندوق پستی: ۱۵۹۷۶۳۳۱۱۱

تلفن: ۸۸۶۹۰۰۲۲ شماره: ۸۸۶۹۰۰۲۲

www.lsi.ir

همه حقوق محفوظ و متعلق به «نشر نویسه پارسی» است.
تکثیر، انتشار و ترجمه این اثر یا قسمتی از آن به هر شیوه، بدون مجوز قبلی و کتبی ممنوع
و مورد پیگرد قانونی قرار خواهد گرفت.

شابک: ۹۷۸-۶۲۲-۶۶۴۹-۲۲-۳

ISBN: 978-622-6649-22-3

مجموعه مقالات سومین همایش ملی زبان‌شناسی پیکره‌ای

آزاده میرزایی	به کوشش
مقصومه استاجی	ویراستار چکیده‌های انگلیسی
(عضو هیئت علمی دانشگاه علامه طباطبائی)	
www.mehraabi.com محمد محرابی	طرح جلد و یونیفورم
www.mehraabi.com محمد محرابی	صفحه‌آرایی و آماده‌سازی چاپ
روز	چاپ و صحافی
۳۰۰ نسخه	شمارگان
اول، ۱۳۹۸	نوبت چاپ
۵۵۰۰۰ تومان	قیمت

مجموعه مقالات سومین همایش ملی زبان‌شناسی پیکره‌ای

برگزارکننده

انجمن زبان‌شناسی ایران

با همکاری

پژوهشگاه علوم انسانی و مطالعات فرهنگی

پایگاه استنادی علوم جهان اسلام (ISC)

نشر نویسه پارسی

سازمان همایش

دکتر آزاده میرزائی دبیر علمی

زهرا ابراهیم بانکی دبیر اجرایی

کمیته علمی

دکتر محرم اسلامی دانشگاه زنجان

دکتر محمد بحرانی دانشگاه علامه طباطبائی

دکتر محمود بی‌جن خان دانشگاه تهران

دکتر پروانه خسروی زاده دانشگاه صنعتی شریف

دکتر مصطفی عاصی پژوهشگاه علوم انسانی و مطالعات فرهنگی

دکتر مسعود قیومی پژوهشگاه علوم انسانی و مطالعات فرهنگی

دکتر شهرام مدرس خیابانی دانشگاه آزاد اسلامی کرج

دکتر امیرسعید مولودی دانشگاه شیراز

دکتر سید ابوالقاسم میرروشن دل دانشگاه گیلان

دکتر آزاده میرزائی دانشگاه علامه طباطبائی

هیئت داوران

دکتر محرم اسلامی	دانشگاه زنجان
دکتر محمد بحرانی	دانشگاه علامه طباطبائی
دکتر محمود بی‌جن‌خان	دانشگاه تهران
دکتر پروانه خسروی‌زاده	دانشگاه صنعتی شریف
دکتر ویدا شقاقی	دانشگاه علامه طباطبائی
دکتر مصطفی عاصی	پژوهشگاه علوم انسانی و مطالعات فرهنگی
دکتر مسعود قیومی	پژوهشگاه علوم انسانی و مطالعات فرهنگی
دکتر شهرام مدرس خیابانی	دانشگاه آزاد اسلامی کرج
دکتر امیرسعید مولودی	دانشگاه شیراز
دکتر سید ابوالقاسم میرروشن‌دل	دانشگاه گیلان
دکتر میرسعید موسوی رضوی	دانشگاه علامه طباطبائی
دکتر آزاده میرزائی	دانشگاه علامه طباطبائی

کمیته اجرایی

زهرا ابراهیم بانکی، زهرا خلجی، مریم رمضانخانی، سلیمه زمانی،
بیبا قوچانی، طاهره همتی

فهرست مطالب

- ۹ پیشگفتار
- ۱۱ تهیه دادگان‌های گفتاری و متنی برای سامانه‌ی بازشناسی خودکار مکالمات خلبان و واحدهای مراقبت پرواز
محمد بحرانی - مهسا آزادمش
- ۳۷ استخراج قواعد واجی زبان فارسی از پیکره‌ی آوایی فارسی‌دات
محمود بی‌جن‌خان - عرفان بنیادی
- ۵۱ استفاده از پیکره‌های بارگذاری شده در پایگاه دادگان زبان فارسی به منظور بررسی صفات مرکب زبان فارسی
بهار پورشاهیان
- ۶۷ بررسی پیکره‌بنیاد جوک فارسی از منظر تحلیل انتقادی گفتمان
سهیل دانش‌زاده - علی افخمی
- ۹۱ بررسی زبانی پسوندهای نام‌خانوادگی در زبان فارسی:
پژوهشی پیکره‌بنیاد
آناهید دشتی - فاطمه سلطان‌زاده
- ۱۱۳ بررسی پیکره‌بنیاد مقوله معنایی پیشوند (نا-) در زبان فارسی
فریبا صیادی پور سی سخت - امیر سعید مولودی
- ۱۳۹ معرفی پیکره «کودک علامه»: نخستین پیکره زبان گفتاری و نوشتاری کودکان فارسی‌زبان
الهه طاهری قلعه‌نو - محمد دبیرمقدم
- ۱۵۷ گروه‌بندی معنایی ترکیبات اسمی زبان فارسی به همراه ساخت بانک داده
شهره طباطبایی سیفی - محمد ایزدی
- ۱۸۱ معرفی داده استاندارد طلایی در سطح معنا برای هم‌نگاره‌های زبان فارسی
مسعود قیومی

- ۲۰۹ آغازگر بی‌نشان جملات پرسشی پرسش‌واژه‌ای در زبان فارسی
آزاده میرزائی
- ۲۱۹ پیکره و سوگیری پژوهشی؛ مطالعه‌ای موردی در تقابل واژگانی
ماندانا کلاهدوز محمدی - علی رضا قلی فامیان
- ۲۳۳ تحلیل پیکره‌بنیاد خطا در ساختار زبانی دانش‌آموزان استثنایی
پایه اول تا چهارم ابتدایی شاغل به تحصیل در مدارس استثنایی
حنانه رسولی وثوق - شهرام مدرس خیابانی - حمیدرضا ربیعی
- ۲۵۳ آموزش واژه‌های نقشی به فارسی‌آموزان خارجی با بهره‌گیری از
پیکره زبانی
سمیرا میرزائی

Persian Learner Translator Corpus (PeLTC)	3
Ali Beikian, Dariush Najadansari, Mehran Borzoufard	
Applying Data-Driven Learning to EFL Learners' Writing Development: The Case for Micro Level Skills	17
Mehrdad Sepehri	
Abstracts	45

پیشگفتار

سومین همایش ملی زبان‌شناسی پیکره‌ای، در اردیبهشت ۱۳۹۸ در پژوهشگاه علوم انسانی و مطالعات فرهنگی به همت انجمن زبان‌شناسی ایران برگزار شد. برای این همایش ۲۰ مقاله از دانشگاه‌ها و مراکز تحقیقاتی سراسر ایران به دبیرخانه همایش ارسال شد که از میان آنها، پس از داوری، ۱۵ مقاله برای سخنرانی و چاپ برگزیده شد.

کارآمدی پیکره‌ها در پژوهش‌های نظری و کاربردی مرتبط با زبان، سبب شده است تا ساخت پیکره‌ها از یک سو و روش‌ها و رویکردها در بهره‌برداری از پیکره‌ها با اهداف پژوهشی متنوع، در سوی دیگر مورد توجه پژوهشگران حوزه‌های مختلف قرار بگیرد. امروزه زبان‌شناسی پیکره‌ای چه در مقام ابزاری پژوهشی که بررسی پدیده‌ها و نظریات مطرح در زبان را هدف قرار می‌دهد و چه در جایگاهی که صدور فرضیات و نظریات زبانی را رقم می‌زند، جزئی جدایی‌ناپذیر از پژوهش‌های زبانی است. در ارتباط با زبان فارسی در حال حاضر دستاوردهای ارزنده‌ای هم به لحاظ کمی و سرعت پیشرفت محتوا و هم از جهت تعداد، در دست است. مجموعه مقالات دو همایش پیشین زبان‌شناسی پیکره‌ای و مجموعه حاضر شاهی بر این مدعا هستند.

امید است مجموعه حاضر که دربرگیرندهٔ وجوه مختلفی از مطالعات زبان‌شناسی پیکره‌ای در موضوعات فرایندهای شکل‌گیری برخی پیکره‌های برچسب‌خورده و نخورده، پردازش زبان طبیعی با استفاده از پیکره‌های زبانی، کاربرد پیکره در آموزش زبان، تحلیل گفتمان و استخراج روال‌ها، الگوها و قواعد زبان فارسی بر اساس پیکره‌های موجود است، در بالندگی این حوزه مطالعاتی مفید واقع شود.

لازم است از بزرگانی که در شکل‌گیری این همایش تلاش کردند، تشکر کنم؛ نخست از رئیس انجمن زبان‌شناسی ایران، سرکار خانم دکتر بلقیس روشن؛ مسئولان محترم پژوهشگاه علوم انسانی و مطالعات فرهنگی؛ رئیس

پژوهشکدهٔ زبان‌شناسی پژوهشگاه جناب آقای دکتر مصطفی عاصی؛ دبیر اجرایی سرکار خانم زهرا ابراهیم‌بانکی و همچنین شورای اجرایی همایش که بزرگوارانه در اجرای همایش بسیار کوشیدند. همچنین از سرکار خانم دکتر معصومه استاجی برای ویرایش چکیده‌های انگلیسی مقالات و از جناب آقای امیر احمدی مدیر محترم نشر نویسهٔ پارسی برای همراهی‌هایشان در چاپ مجموعهٔ مقالات سپاسگزارم.

بر خود لازم می‌دانم از کمیتهٔ علمی و هیأت داوری همایش و از استادان، دانشجویان و پژوهشگران گرانقدر که با ارسال مقاله خود به عنای علمی این همایش افزودند و دستاوردهای پژوهشی خود را سخاوت‌مندانه با علاقمندان این حوزه در میان گذاشتند صمیمانه سپاسگزاری کنم.

آزاده میرزائی

اردیبهشت ۱۳۹۸

تهیه دادگان‌های گفتاری و متنی برای سامانه‌های بازشناسی خودکار مکالمات خلبان و واحدهای مراقبت پرواز

محمد بحرانی^۱

مهسا آزادمنش^۲

چکیده

این مقاله به مرحله آماده‌سازی پیکره‌های گفتاری و متنی برای یک سامانه بازشناسی گفتار خاص منظوره به نام «سامانه بازشناسی خودکار مکالمات خلبان و واحدهای مراقبت پرواز» می‌پردازد. در این مقاله، در اولین مرحله از طراحی سامانه بازشناسی گفتار، به تهیه دادگان‌های گفتاری و متنی موردنیاز برای آموزش سامانه می‌پردازیم. بدین منظور، بخش‌هایی از مکالمات واقعی صورت‌گرفته بین خلبان‌ها و برج مراقبت را از واحد مراقبت فرودگاه مهرآباد با اخذ مجوزهای لازم دریافت کردیم. مکالمات جمع‌آوری شده ابتدا پالایش شده و بخش‌های اضافی آن حذف می‌گردد و سپس توسط افراد خبره، متن معادل با آنها مطابق با یک سری استانداردهای خاص، تولید می‌شود. در مرحله بعد، فایل‌های صوتی مکالمات به همراه معادل متنی آنها به قطعات کوچکتر تقسیم می‌شوند؛ همچنین صورت‌های واجی انواع کلمات موجود در متن به صورت دستی تولید می‌شود. برای تهیه دادگان متنی نیز علاوه بر متون مربوط به مکالمات، داده‌های متنی دیگری نیز از منابع مرتبط جمع‌آوری می‌شود. داده‌های متنی، مورد پالایش و یک‌دست‌سازی قرار می‌گیرند و در نهایت کلمات موجود در آنها استخراج می‌شود تا در مراحل بعد واج‌نویسی گردند. این کلمات به همراه کلمات استخراجی از دادگان صوتی، مجموعه وازگان سامانه بازشناسی گفتار را تشکیل می‌دهند. در این پژوهش، در حدود ۱۵۲

^۱ استادیار، دانشکده علوم ریاضی و رایانه، دانشگاه علامه طباطبائی، bahrani@atu.ac.ir

^۲ دانش‌آموخته کارشناسی ارشد زبان‌شناسی رایانشی، دانشگاه صنعتی شریف؛

mahsa.azadmanesh@yahoo.com

دقیقه مکالمه صوتی به صورت تقطیع و برجسب‌دهی شده و همچنین یک دادگان متنی پالایش‌شده با حدود ۶۳۴۰۰ کلمه جمع‌آوری شده است. این داده‌ها در مراحل بعدی پژوهش، برای آموزش مدل‌های صوتی و زبانی سامانه بازشناسی گفتار به کار می‌روند.

کلیدواژه‌ها: بازشناسی گفتار، دادگان مکالمات هوانوردی، پیکره خاص منظوره

۱. مقدمه

۱-۱. بیان مسئله

در حال حاضر در کشور بعد از بروز حوادث و رویدادهای مخاطره‌آمیز هوانوردی، مکالمات صورت‌گرفته بین خلبان‌ها و کنترل‌کننده‌های ترافیک هوایی (برج مراقبت)، توسط سازمان هواپیمایی کشوری مجدداً بررسی شده و این مکالمات توسط تیمی آشنا به مباحث هوانوردی، با صرف هزینه و وقت بسیار زیاد، به صورت دستی به متن تبدیل می‌شوند. این متون بعداً در صورت لزوم در مراجع قضایی مورد استفاده قرار می‌گیرند. «سامانه بازشناسی خودکار مکالمات خلبان و واحدهای مراقبت پرواز» به پیاده‌سازی خودکار این مکالمات (تبدیل مکالمات به متن) کمک می‌کند تا در مواقع ضروری از متون مکالمات استفاده شود.

هدف نهایی ما در این پژوهش طراحی یک سامانه بازشناسی گفتار است که کار متنی‌سازی را به صورت خودکار انجام دهد تا در وقت و هزینه نیروی انسانی صرفه‌جویی شده و نیروی انسانی فقط نقش ناظر را داشته باشد.

از آنجاکه برای آماده‌سازی هر سامانه بازشناسی گفتار خاص منظوره (و با شرایط محیطی خاص)، ابتدا باید یک دادگان از سیگنال‌های گفتاری در همان زمینه موردنظر و همچنین یک دادگان متنی از متون همان وظیفه^۱ تهیه کرد، در این پژوهش و در اولین مرحله از طراحی سامانه بازشناسی

^۱ task

گفتار، به جمع‌آوری و پالایش مکالمات واقعی صورت‌گرفته بین خلبان‌ها و برج مراقبت می‌پردازیم و همچنین متن مکالمات را نیز به صورت دستی تهیه می‌کنیم. در مراحل بعدی پژوهش این داده‌ها برای آموزش مدل‌های صوتی و زبانی سامانه‌های بازشناسی گفتار متن‌باز کلدی^۱ (پوی^۲ و همکاران، ۲۰۱۱) به کار می‌روند تا در نهایت «سامانه‌های بازشناسی خودکار مکالمات خلبان و واحدهای مراقبت پرواز» طراحی و توسعه داده شود.

۱-۲. اهمیت و ضرورت انجام پژوهش

به دلایل زیر سامانه‌های معمول بازشناسی گفتار را نمی‌توان به منظور بازشناسی مکالمات خلبان و برج مراقبت به کار برد و باید با جمع‌آوری دادگان (گفتاری و متنی) مرتبط با این وظیفه، یک سامانه‌های بازشناسی گفتار مختص این کار طراحی کرد:

- به دلیل وجود نوفه^۳ زیاد در مکالمات هوایی، شرایط و محیط آکوستیکی مکالمات با محیط‌های آرام اداری که سامانه‌های معمول بازشناسی گفتار در آنها آموزش دیده‌اند، بسیار متفاوت است. بنابراین دادگان‌های گفتاری معمول که برای آموزش مدل‌های صوتی در سامانه‌های بازشناسی گفتار استفاده می‌شوند، در اینجا کارایی نداشته و باید از داده‌های واقعی مربوط به مکالمات هوایی استفاده کنیم تا بتوانیم گفتار نوفه‌ای را مدل‌سازی کنیم یا سامانه‌های موجود را با این داده‌ها تطبیق^۴ دهیم.

- مکالمات هوانوردی دارای ادبیات خاص خود هستند و علاوه بر اینکه از قالب‌های خاصی پیروی می‌کنند، دارای کلمات و واژه‌های تخصصی

¹ Kaldi

² Povey

³ noise

⁴ adapt

خاصی هستند که در مکالمات روزمره به کار نمی‌روند. بنابراین مدل‌های زبانی موجود در سامانه‌های معمول بازشناسی به‌خوبی قادر به پیش‌بینی این سبک از جملات و واژه‌ها نیست. بنابراین باید مدل زبانی و مجموعه واژگان خاص مکالمات هوانوردی را فراهم کرد و آنها را در سامانه بازشناسی به کار برد و یا اینکه مدل‌های زبانی موجود را با آنها تطبیق داد.

به علت حساسیت بالای هوانوردی، موضوع نظارت انسان بر روی تبدیل مکالمات به متن حذف نخواهد شد. از آنجایی که در کشور ما تبدیل مکالمات به داده متنی زمانی صورت می‌گیرد که اتفاقی مخاطره‌آمیز یا سانحه‌ای رخ داده باشد و این داده‌های متنی در بسیاری از موارد در مراجع قضایی کاربرد دارند، نظارت انسان بر روی پیاده‌سازی مکالمات، لازم بوده و سامانه بازشناسی خودکار مکالمات نقش تسریع و تسهیل این روند را بر عهده خواهد داشت.

طبق استانداردهای بین‌المللی، مکالمات هوانوردی باید به زبان انگلیسی و با استفاده از اصطلاحات استاندارد هوانوردی صورت گیرد؛ بنابراین شاید این ایده به ذهن برسد که بتوان از سامانه‌های خارجی که بدین‌منظور طراحی شده‌اند استفاده کرد. ولی به دلایل زیر، سامانه‌های خارجی مناسب استفاده در داخل نیستند:

- گاهی خلبانان یا کنترل‌کننده‌های ترافیک هوایی، از تلفظ و اصطلاحات استاندارد پیروی نمی‌کنند و عموماً از زبان مادری خود (اکثراً فارسی) برای توصیف شرایط هوایی استفاده می‌کنند. بنابراین سامانه‌های خارجی نمی‌توانند پاسخگوی نیاز هوانوردی کشور باشند. از طرفی حتی در صورت صحبت به زبان انگلیسی نیز، لهجه بیان مکالمات با لهجه افراد بومی انگلیسی‌زبان (یا افرادی با زبان مادری غیرفارسی) بسیار متفاوت

است. بنابراین سامانه‌های بازشناسی گفتار که با لهجه‌های بومی انگلیسی یا سایر لهجه‌ها آموزش دیده‌اند، نمی‌توانند مناسب استفاده در داخل کشور باشند.

- با اینکه در تمام دنیا مکالمات هوانوردی دارای نوفه زیاد هستند، ولی نوع نوفه بسته به کشورهای مختلف و کانال‌های مخابراتی مختلف بسیار متفاوت است. در نتیجه نمی‌توان سامانه‌ای که با یک نوفه خاص تطبیق یافته را برای بازشناسی سیگنال‌های صوتی با نوفه متفاوت به کار برد.

- در مکالمات هوانوردی کشور ما، نام شهرها و فرودگاه‌هایی به کار می‌رود که مختص کشور ایران بوده و در نتیجه در واژگان سامانه‌های خارجی وجود ندارد. بنابراین سامانه‌های بازشناسی خارجی قادر به تشخیص آنها نیستند.

مجموع دلایل بالا اهمیت و ضرورت انجام پژوهشی مستقل در داخل کشور را نشان می‌دهد.

۱-۳. چالش‌های تحقیق

عدم دسترسی به حجم زیادی از داده، وجود نوفه، وجود لهجه‌های مختلف، عدم رعایت اصطلاحات هوانوردی و صحبت به زبان مادری به جای انگلیسی، از چالش‌های کار بازشناسی گفتار هوانوردی در ایران است.

یکی از چالش‌های دست‌وپاگیر در روند انجام این پژوهش، عدم دسترسی به داده‌های هوانوردی بود. از آنجاکه مکالمات هوانوردی عمدتاً محرمانه بوده و در مورد برخی از آنها ملاحظات امنیتی برقرار است، دسترسی به آنها بسیار مشکل بوده و نیازمند طی مراحل اداری پیچیده و اخذ مجوزهای لازم می‌باشد.

چالش دیگری که در کار وجود دارد رعایت نکردن استانداردهای هوانوردی در برخی از مکالمات است. همان‌طور که گفتیم، مکالمات هوانوردی باید به زبان انگلیسی صورت گیرد؛ ولی گاهی خلبانان یا واحدهای کنترل ترافیک، این امر را رعایت نمی‌کنند. وجود زبان‌ها و گویش‌های مختلف، مانند فارسی، آذری، کردی و غیره در مکالمات انگلیسی هوانوردی از چالش‌های دیگر این پژوهش است.

۲. مرور مختصری بر پیشینه پژوهش

اولین سیستم تشخیص گفتار هوانوردی در جهان وِیس‌فلایت^۱ نام دارد که توسط اداره هوانوردی فدرال آمریکا^۲ برای استفاده در هواپیماهای غیرنظامی مجاز شمرده شده است (ویس‌فلایت، ۲۰۱۶). این سامانه از طریق کلید نصب‌شده بر روی یوک^۲ فعال می‌شود. خلبان، کلمات اختصاری مربوط به ایستگاه‌های بین‌راهی (که شامل سه حرف الفبای انگلیسی است) را می‌گوید و سامانه، این سرواژه‌ها را در واحد ناوبری وارد می‌کند.

اگر قرار باشد این سرواژه‌ها به‌صورت دستی وارد سامانه شوند خلبان باید برای هر جایگاه، پیچ مشخصی را آن‌قدر بچرخاند تا نمایشگر به حرف موردنظر برسد. سپس به جایگاه بعد بپرد و دوباره پیچ مربوط به حروف الفبا را بچرخاند تا جایگاه بعد نیز پر شود. انجام این کار بسیار زمان‌بر است. درحالی‌که با استفاده از سامانه مذکور خلبان فقط با تلفظ حروف، کلمات اختصاری ایستگاه‌های بین‌راهی را وارد می‌کند. این سامانه فقط برای بازشناسی نام اختصاری فرودگاه‌های بین‌راهی از طریق بیان گفتاری حروف

^۱ VoiceFlight

^۲ Federal Aviation Agency (FAA)

الفبا است (وارن^۱، ۲۰۱۶) و برای بازشناسی سایر مکالمات خلبان به کار نمی‌رود.

در پژوهش‌های بعدی، پاردو^۲ و همکاران (۲۰۱۱) در دانشگاه پلی‌تکنیک مادرید، یک سامانه‌ی بازشناسی گفتار هوانوردی طراحی کردند که قادر است مکالمات را همزمان از دو زبان اسپانیایی و انگلیسی تشخیص داده و به متن تبدیل کند. آنها در کار خود به دقت ۸۶٪ دست یافتند. از آنجاکه تعداد کلمات و عبارات در مکالمات هوانوردی محدود است، تشخیص گفتار با دقت بالاتری صورت می‌گیرد.

جانسون^۳ و همکاران (۲۰۱۳) نیز در اداره‌ی هوانوردی فدرال آمریکا و شرکت برین‌ونشنز^۴، سامانه‌ای به نام والس‌وکس^۵ ارائه دادند که قادر به تشخیص و درک مفاهیم موجود در مکالمات هوانوردی می‌باشد.

نگوین^۶ و هولون^۷ (۲۰۱۵) در مقاله‌ی خود ضمن مروری بر سوابق موضوع، چالش‌ها و مشکلات سامانه‌های تشخیص گفتار هوانوردی را بررسی کرده و یک سیستم اولیه برای آن ارائه دادند و سپس نگوین در پایان‌نامه خود با به‌کارگیری اطلاعات زبانی، سامانه تشخیص مکالمات هوانوردی اولیه را بهبود داد (نگوین، ۲۰۱۶).

۳. جمع‌آوری و آماده‌سازی داده‌ی گفتاری

۳-۱. جمع‌آوری داده‌ی اولیه

¹ Warren

² Pardo

³ Johnson

⁴ Brain Ventions

⁵ ValsVox

⁶ Nguyen

⁷ Holone

در اولین مرحله از کار تهیه دادگان، نیازمند جمع‌آوری داده‌های خام هستیم. بدین‌منظور، طبق مذاکراتی با واحد مراقبت فرودگاه مهرآباد، مقداری داده صوتی ضبط‌شده از مکالمات هوانوردی را با اخذ مجوزهای لازم دریافت کردیم. حجم داده‌هایی که در اختیارمان قرار گرفت محدود بود و در بسیاری از موارد پیوستگی نداشت. بخشی از داده‌های صوتی مکالمات، برچسب متنی داشتند که البته به دلیل عدم تطابق کامل با فایل صوتی از این برچسب‌ها استفاده چندانی نشد.

مکالماتی که در دست داریم شامل دو دسته هستند. دسته اول مربوط به مکالمات روزمره خلبانان خطوط مختلف هواپیمایی و برج مراقبت و دسته دوم، بخش‌هایی از ۹ رویداد جزئی پروازی که در سال ۱۳۹۱ برای هواپیماهای سه شرکت هواپیمایی هما، ماهان و نفت اتفاق افتاده‌اند. به دلیل تفاوت شرایط هوانوردی در مواقع عادی و در شرایط مخاطره‌آمیز، سبک جملات این دو دسته از داده‌ها متفاوتند. بخش‌هایی چند دقیقه‌ای از مکالمات دسته دوم از روی نوار ضبط‌شده پیاده‌سازی شده و به متن تبدیل شده‌اند. به علت محرمانه بودن این داده‌ها امکان دسترسی به تمامی مکالمات این ۹ رویداد وجود نداشت. بنابراین بخش‌هایی غیرپیوسته از مکالمات بین کنترل‌کننده‌ها و خلبانان در اختیار ما قرار گرفت.

مکالمات دسته اول یعنی مکالمات عادی روزمره شامل ۲۷۸ فایل صوتی به فرمت mp3 با حجم مجموعاً ۲۶۹ مگابایت و نرخ بیت^۱ ۱۲۸ کیلوبیت بر ثانیه هستند. مکالمات تماماً به زبان انگلیسی می‌باشند.

مکالمات دسته دوم خود شامل سه گروه از فایل‌های صوتی می‌باشد. گروه اول شامل ۱۲۳ فایل صوتی استریو به فرمت wav با حجم مجموعاً ۲۳۱ مگابایت داده خام می‌باشد که با نرخ نمونه‌برداری^۲ ۸ کیلوهرتز (معادل نرخ

^۱ Bit rate

^۲ Sampling rate

بیت ۲۵۶ کیلوبیت بر ثانیه) ضبط شده‌اند. گروه دوم شامل ۱۰ فایل صوتی به فرمت wmv با حجم مجموعاً ۱۷۲ مگابایت و با نرخ بیت ۱۲۸ کیلوبیت بر ثانیه می‌باشد. گروه سوم نیز شامل ۱۱۳ فایل صوتی با فرمت mp3 با حجم مجموعاً ۵۹,۳ مگابایت و با نرخ بیت ۲۴ کیلوبیت بر ثانیه است. حدود هفتاد درصد از مکالمات دسته دوم به زبان فارسی و حدود سی درصد به زبان انگلیسی صورت گرفته‌اند. در جدول ۱ جمع‌بندی این داده‌ها آمده است.

جدول ۱. ویژگی داده‌های صوتی خام (پیش از پالایش)

۲۶۹	۱۲۸	mp3	۲۷۸	
۲۳۱	۲۵۶	wav	۱۲۳	گروه اول
۱۷۲	۱۲۸	wmv	۱۰	گروه دوم
۵۹,۳	۲۴	mp3	۱۱۳	گروه سوم

در مکالمات به‌طور عمده از اصطلاحات هوانوردی استفاده شده است، در نتیجه ساختار جملات ساده و دایره لغات محدودند. نحو جملات ساده هستند. گوینده‌ها همه مرد هستند. میزان نوفه داده‌ها خیلی زیاد است به‌طوری‌که فهم بیشتر مطالب برای کسی که گوشش با محیط پروازی آشنایی ندارد تقریباً غیرممکن است. در مکالمات گاهی نوفه به حدی زیاد می‌شود که بار اول خلبان یا برج مراقبت به‌طور درست متوجه پیام ردوبدل شده نمی‌شوند و مجبور هستند پیام را تکرار کنند.

۳-۲. پالایش داده‌های گفتاری

داده‌های گفتاری قبل از استفاده باید پالایش شوند. معادل متنی داده‌ها باید تولید شود. همان‌طور که گفتیم، مکالمات هوانوردی باید انگلیسی باشند ولی بین آنها ممکن است مکالمات فارسی یا آذری نیز وجود داشته باشد. در این

پژوهش در مرحله اول تمرکز ما فقط بر روی مکالمات انگلیسی است؛ بنابراین بخش‌های غیرانگلیسی در مرحله پالایش از سیگنال صوتی حذف می‌شوند. ضمناً داده‌ها باید از نظر میزان نوفه بررسی شوند و داده‌هایی که نوفه آنها از حدی بیشتر است حذف گردند. پالایش داده‌ها یکی از مراحل زمان‌بر و پرمحمت از کار تهیه دادگان است زیرا بیشتر مراحل کار به صورت دستی انجام می‌شود. مراحل زیر به ترتیب برای پالایش داده‌ها به کار رفت:

۱. تبدیل فایل‌های گفتاری به فرمت wav: همان‌طور که گفتیم، داده‌ها در سه فرمت wav، wmv و mp3 تحویل گرفته شدند. در اولین مرحله از پالایش داده‌ها، با استفاده از ابزار Cool Edit همه داده‌ها به قالب wav تبدیل شدند.

۲. یکسان‌سازی نرخ نمونه‌برداری: در مرحله بعد، نرخ نمونه‌برداری همه فایل‌های wav به حالت ۱۶ کیلوهرتز، ۱۶ بیت و مونو (معادل نرخ بیت ۲۵۶ کیلوبیت در ثانیه) درآمدند. همان‌طور که گفتیم، داده‌های wav اولیه با نرخ ۸ کیلوهرتز نمونه‌برداری شده بودند. این داده‌ها در واقع upsample شدند تا به نرخ ۱۶ کیلوهرتز برسند. همچنین این فایل‌ها استریو بودند که به مونو تبدیل شدند. مرحله یکسان‌سازی نرخ نمونه‌برداری به صورت خودکار و با ابزار SoX انجام گرفت.

دلیل تبدیل داده‌ها به فرمت و نرخ نمونه‌برداری مذکور این است که ابزارهای بازشناسی گفتار که در مراحل بعد از آن استفاده می‌کنیم، عمدتاً با این فرمت کار می‌کند.

۳. حذف بخش‌های گفتاری فارسی: همان‌طور که گفتیم بخش زیادی از داده‌ها در دسته دوم، شامل مکالمات فارسی هستند. دلیل فارسی بودن این داده‌ها این است که معمولاً خلبانان در هنگام مواجهه با رویدادهای مخاطره‌آمیز به زبان مادری خود صحبت می‌کنند. بنابراین گفتار فارسی