



تشخیص عبارتهای گفتاری برای اخبار فارسی صداوسیمای جمهوری اسلامی ایران

هادی ویسی^{۱*}، سید اکبر قریشی^۲ و اعظم باستانفرد^۳

^۱ دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران

^۲ دانشکده فنی و مهندسی رسانه، دانشگاه صداوسیما، تهران، ایران

^۳ دانشگاه آزاد اسلامی واحد کرج، کرج، ایران

چکیده

هدف از تشخیص عبارتهای گفتاری یا جستجوی کلیدواژه، تشخیص و جستجوی مجموعه‌ای از کلیدواژه‌ها در مجموعه‌ای از اسناد گفتاری (مانند سخنرانی‌ها، جلسه‌ها) است. در این پژوهش تشخیص عبارتهای گفتاری فارسی برپایه سامانه‌های بازشناسی گفتار با کاربرد در بازیابی اطلاعات در بایگانی‌های گفتاری و ویدئویی سازمان صدا و سیما طراحی و پیاده‌سازی شده است. برای این کار، ابتدا اسناد گفتاری به متن، بازشناسی، سپس بر روی این متون جستجو انجام می‌شود. برای آموزش سامانه بازشناسی گفتار فارسی، دادگان فارسی‌دات بزرگ به کار رفته است. این سامانه به نرخ خطای واژه ۲/۷۱ درصد بر روی همین دادگان و ۲۸/۲۳ درصد بر روی دادگان اخبار فارسی با استفاده از مدل زیر فضای مخلوط گوسی (SGMM) رسید. برای تشخیص عبارتهای گفتاری از روش پایه واژگان نماینده استفاده شده و با استفاده از شبکه حافظه کوتاه-مدت ماندگار و دسته‌بندی زمانی پیوندگرا (LSTM-CTC) روشی برای بهبود تشخیص واژگان خارج از واژگان (OOV) پیشنهاد شده است. کارایی سامانه تشخیص عبارات با روش واژه‌های نماینده بر روی دادگان فارسی‌دات بزرگ بر طبق معیار ارزش وزنی واقعی عبارت (ATWV) برابر با ۰/۹۲۰۶ برای کلیدواژه‌های داخل واژگان و برابر با ۰/۲ برای کلیدواژه‌های خارج از واژگان رسید که این نرخ برای واژگان OOV با استفاده از روش LSTM-CTC با حدود پنجاه درصد بهبود به مقدار ۰/۳۰۵۸ رسید؛ همچنین، در تشخیص عبارتهای گفتاری بر روی دادگان اخبار فارسی، ATWV برابر ۰/۸۰۰۸ حاصل شد.

واژگان کلیدی: تشخیص عبارتهای گفتاری فارسی، جستجوی کلیدواژه، بازشناسی گفتار، سازمان صداوسیما، کلدی

Spoken Term Detection for Persian News of Islamic Republic of Iran Broadcasting

Hadi Veisi^{1*}, Sayed Akbar Ghoreishi² & Azam Bastanfard³

¹ Faculty of New Sciences and Technologies, University of Tehran, Tehran, Iran

² Department of Media Engineering, IRI Broadcast University, Tehran, Iran

³ Karaj Islamic Azad University, Karaj, Iran

Abstract

Islamic Republic of Iran Broadcasting (IRIB) as one of the biggest broadcasting organizations, produces thousands of hours of media content daily. Accordingly, the IRIB's archive is one of the richest archives in Iran containing a huge amount of multimedia data. Monitoring this massive volume of data, and brows and retrieval of this archive is one of the key issues for this broadcasting. The aim of this research is to design a content retrieval engine for the IRIB's media and production using spoken term detection (STD) or keyword spotting. The goal of an STD system is to search for a set of keywords in a set of speech documents. One of the methods for STD is using a speech recognition system in which speech is recognized and converted into text and then, the text is searched for the keywords. Variety of speech documents and the limitation of speech recognition vocabulary are two challenges of this approach. Large vocabulary

* Corresponding author

*نویسنده عهده‌دار مکاتبات

continuous speech recognition systems (LVCSR) usually have limited but large vocabulary and these systems can't recognize out of vocabulary (OOV) words. Therefore, LVCSR-based STD systems suffer OOV problem and can't spotting the OOV keywords. Methods such as the use of sub-word units (e.g., phonemes or syllables) and proxy words have been introduced to overcome the vocabulary limitation and to deal with the out of vocabulary (OOV) keywords.

This paper proposes a Persian (Farsi) STD system based on speech recognition and uses the proxy words method to deal with OOV keywords. To improve the performance of this method, we have used Long Short-Term Memory-Connectionist Temporal Classification (LSTM-CTC) network.

In our experiments, we have designed and implemented a large vocabulary continuous speech recognition systems for Farsi language. Large FarsDat dataset is used to train the speech recognition system. FarsDat contains 80 hours voices from 100 speakers. Kaldi toolkit is used to implement speech recognition system. Since limited dataset, Subspace Gaussian Mixture Models (SGMM) is used to train acoustic model of the speech recognition. Acoustic model is trained based context tri-phones and language model is probability tri-gram words model. Word Error Rate (WER) of Speech recognition system is 2.71% on FARSDAT test set and also 28.23% on the Persian news collected from IRIB data.

Term detection is designed based on weighted finite-state transducers (WFST). In this method, first a speech document is converted to a lattice by the speech recognizer (the lattice contains the full probability of speech recognition system instead of the most probable one), and then the lattice is converted to WFST. This WFST contains the full probability of words that speech recognition computed. Then, text retrieval is used to index and search over the WFST output. The proxy words method is used to deal with OOV. In this method, OOV words are represented by similarly pronunciation in-vocabulary words. To improve the performance of the proxy words methods, an LSTM-CTC network is proposed. This LSTM-CTC is trained based on characterers of words separately (not a continuous sentence). This LSTM-CTC recomputed the probabilities and re-verified proxy outputs. It improves proxy words methods dues to the fact that proxy words method suffers false alarms. Since LSTM-CTC is an end-to-end network and is trained based on the characters, it doesn't need a phonetic lexicon and can support OOV words. As the LSTM-CTC is trained based on the separate words, it reduces the weight of the language model and focuses on acoustic model weight.

The proposed STD achieve 0.9206 based Actual Term Weighted Value (ATWV) for in vocabulary keywords and for OOV keywords ATWV is 0.2 using proxy word method. Applying the proposed LSTM-CTC improves the ATWV rate to 0.3058. On Persian news dataset, the proposed method receives ATWV of 0.8008.

Keywords: Persian Spoken Term Detection, IRIB, Persian News, Keyword Spotting, Speech Recognition, Kaldi

اظهار می‌کند و نتایج مرتبط با نیاز کاربر در قالب چندرسانه‌ای نمایش داده می‌شود [2]. ابزار و روش‌های پایه جستجو در محتواهای گفتاری را تشخیص عبارت‌های گفتاری (STD)^۶ می‌نامند. طبق تعریفی که مؤسسه ملی فناوری و استانداردهای آمریکا (NIST)^۷ از تشخیص عبارت‌های گفتاری ارائه کرده است؛ هدف از تشخیص عبارت‌های گفتاری، تشخیص سریع وجود یک عبارت -یک دنباله از واژه‌های گفتاری متوالی- در یک پیکره بزرگ صوتی از داده‌های گفتاریِ ناهمگون است [3].

با توجه به گسترش روزافزون محتوای چندرسانه‌ای در بسترهای مختلف مانند پخش همگانی و اینترنت، جستجو بر بستر آن‌ها اهمیت بیش‌تری پیدا می‌کنند، جستجوهای مانند جستجو بر مبنای بافت صدا، تصویر و ویدئو. تشخیص عبارت‌های گفتاری این امکان را فراهم می‌کند که هر سند گفتاری، حاوی هر عبارت از نمایش متنی آن، بازیابی شود؛ درواقع تشخیص عبارت‌های گفتاری مرحله مقدماتی برای

۱- مقدمه

۱-۱- تعریف مسأله

امروزه با گسترش فضای مجازی و شبکه‌های تلویزیونی با حجم انبوهی از اطلاعات و محتوای چندرسانه‌ای روبه‌رو هستیم و این حجم به‌سرعت رو به رشد است؛ همچنین حجم انبوهی از اطلاعات در بایگانی ذخیره شده‌اند. با توجه به ارزش فراوان اطلاعاتی این داده‌ها، نمایه‌کردن^۱، بازیابی^۲، جستجو^۳ و مرور^۴ این اطلاعات، امروزه بسیار موردتوجه قرار گرفته است [1]. هرچند امروزه بازیابی اطلاعات متنی مبتنی بر کلیدواژه موضوعی عمومی و حل‌شده به‌نظر می‌رسد؛ اما جستجو در محتواهای غیرمتنی مانند گفتار یکی از موضوعات مهم پژوهشی است. هدف جستجو بر روی گفتار، بازیابی محتوای گفتاری از منابع صوتی، منطبق با نیاز است؛ کاربر نیاز خود را به‌صورت یک درخواست (پرسش)^۵

- ¹ index
- ² retrieve
- ³ search
- ⁴ browse
- ⁵ query

⁶ Spoken Term Detection (STD)

⁷ National Institute of Standards and Technology (NIST)

برای نیل به هدف موردنظر، در این مقاله بر روی اخبار فارسی صداوسیما تمرکز و از سامانه بازشناسی گفتار استفاده شده است تا گفتار به متن بازشناسی شود؛ سپس با استفاده از الگوریتم مبدل عامل⁵ [10] که یک الگوریتم برای جستجو بر روی متن است، کمک گرفته شده است تا بر روی متن بازشناسی شده، جستجو انجام پذیرد. در این روش فقط واژگان تعریف شده از قبل در سامانه بازشناسی گفتار قابل تشخیص هستند. برای جستجوی واژگان خارج از واژگان (OOV)⁶، سامانه بازشناسی گفتار واژه‌های نماینده به کار گرفته شده‌اند و برای بهبود این روش از یک شبکه حافظه کوتاه-مدت ماندگار با دسته‌بندی زمانی پیوندگرا (LSTM-CTC)⁷ استفاده شده است. در این روش نتایج حاصل از واژه‌های نماینده دوباره بازشناسی و امتیاز اطمینان آن‌ها دوباره تخمین زده می‌شود.

در ادامه مقاله و در بخش دوم، مختصری از پژوهش‌های پیشین بر روی موضوع تشخیص عبارتهای گفتاری بحث و سپس در بخش سوم تعریف دقیق‌تری از تشخیص عبارتهای گفتاری عنوان می‌شود و الگوریتم‌های شاخص‌گذاری، جستجو به صورت مختصر مورد بررسی قرار می‌گیرد. در بخش چهارم روش پیشنهادی برای بازیابی اطلاعات گفتاری توضیح داده و معیارهای ارزیابی و نتایج در بخش پنجم بیان می‌شود. در نهایت بخش ششم به جمع‌بندی و نتیجه‌گیری پژوهش می‌پردازد.

۲- مروری بر پژوهش‌های پیشین

جستجو در گفتار به‌طور تقریبی هم‌زمان با پژوهش‌های بازشناسی گفتار آغاز شد [11]؛ نزدیک به چهل سال پژوهش و توسعه بر روی این عنوان انجام شده و روش‌های زیادی برای آن ارائه شده است که در [1]، [2]، [5] تاریخچه بحث را می‌توانید مطالعه کنید. در پایین در سه گروه خلاصه این روش‌ها آورده شده است.

۲-۱- روش‌های پرسش با مثال^۸

روش‌های پرسش با مثال از جمله نخستین تلاش‌ها برای جستجوی کلیدواژه‌ها هستند [13] و اسم پرسش با مثال این روش را توصیف می‌کند: نمونه‌هایی از کلیدواژه‌ها

بازیابی اسناد گفتاری است [4]؛ لذا کاربردهای اصلی STD را می‌توان نمایه کردن صوت^۱ و داده‌کاوی گفتار^۲ دانست.

چالش‌های اصلی STD را می‌توان به دو دسته کلی تقسیم کرد: یکی گستردگی و تنوع سندهای گفتاری است که می‌توانند به هر صورت مانند گفتارهای پیوسته، گفتارهای گسسته، گفتارهای تمیز و یا همراه با نوفه باشند؛ یکی دیگر از چالش‌ها سرعت و دقت راه‌کارهای ارائه شده است. این راه‌کارها به نسبت راه‌کارهای بازیابی متن هنوز قدرتمند و دقیق نشده‌اند [1]. رویکردهای جستجو در گفتار را می‌توان در دو دسته کلی تقسیم‌بندی کرد:

- روش‌های تطبیق مستقیم آوایی مانند پیچش زمانی پویا^۳ که در آن‌ها سعی بر تطبیق مستقیم ویژگی‌های آوایی بین گفتار و کلیدواژه (پرسش یا درخواست) است.
- استفاده از سامانه‌های خودکار بازشناسی گفتار (ASR)^۴ که در این رویکرد ابتدا گفتار توسط سامانه بازشناسی خودکار گفتار، به متن تبدیل می‌شود؛ سپس با به‌کارگیری روش‌های بازیابی متن، بر روی متن خروجی ASR جستجو انجام می‌شود.

مطالعات گسترده‌ای برای بازیابی گفتار در روی زبان‌ها با منابع وسیع مانند زبان انگلیسی [3]، [5] انجام گرفته است و در سال‌های اخیر پژوهش‌ها بر روی زبان‌ها با منابع محدود مانند پشتو و ویتنامی نیز وجود داشته‌اند و به نتایج مطلوب و قابل قبولی رسیده‌اند [6]، [8]. با این وجود، پژوهش‌ها بر روی زبان فارسی محدود و همراه با دادگان محدود بوده‌اند [9]. با توجه به اهمیت این موضوع در زبان فارسی و به خصوص برای جستجو در منابع دادگانی بزرگ مانند آرشیو سازمان صداوسیما، در این پژوهش بر روی بازیابی اطلاعات از اخبار فارسی صداوسیما پرداخته شده است. بایگانی سازمان صداوسیما یکی از منابع مهم دادگانی گفتاری در زبان فارسی برای جستجو و بازیابی اطلاعات است که با توجه به حجم انبوه داده‌های تولیدی روزانه این سازمان، هر روز به مقدار داده‌های این آرشیو افزوده می‌شود و بازیابی و استخراج اطلاعات از آن یکی از نیازهای سازمان صداوسیما است که در آینده بر اهمیت آن نیز افزوده خواهد شد. کاربردهایی از جمله جستجو در بین بایگانی‌ها و دسترسی به محتوای بایگانی، تحلیل محتوایی برنامه‌های مختلف، نظارت و ارزیابی بر محتوا را می‌توان برای این موضوع در نظر گرفت.

¹ audio indexing

² speech data mining

³ Dynamic Time Warping (DTW)

⁴ Automatic Speech Recognition (ASR)

⁵ Factor transducer

⁶ Out-Of-Vocabulary (OOV)

⁷ Long Short-Term Memory (LSTM) - Connectionist Temporal Classification (CTC)

⁸ Query-by-Example (QbyE)

به‌طور معمول در قالب صدا، برای تشخیص کلیدواژه مورد استفاده قرار می‌گیرند. این روش‌ها به‌طور عمومی شامل دو مرحله هستند: مرحلهٔ بازنمایی الگو که نمونه‌های صوتی کلیدواژه‌ها به‌صورت الگوها در قالب خاصی (ویژگی‌های پسین، مشبک‌ها) نمایش داده می‌شوند و مرحلهٔ تطبیق الگو، که در آن الگوها با گفته‌های^۱ گفتاری هدف مقایسه می‌شوند. در طی دهه‌های گذشته، تمرکز پژوهش در وهلهٔ نخست بر روش‌های جدید بازنمایی الگو بوده است [14]-[19]؛ درحالی‌که اغلب این روش‌ها از برخی از انواع پیچش زمانی پویا^۲ [20] برای تطبیق الگو [21] استفاده می‌کنند. در روش‌های اخیر از روش‌های مبتنی بر شبکه‌های عصبی برای آموزش الگو و تطبیق نمونه‌های صوتی استفاده شده است [22]، [23].

۲-۲- روش‌های کلیدواژه/فیلتر

در روش کلیدواژه/فیلتر که گاهی اوقات به‌عنوان تشخیص آوایی کلیدواژه شناخته می‌شود [12]، کلیدواژه و غیرکلیدواژه (فیلتر) را به‌صورت موازی مدل می‌کنند. در مرحلهٔ تشخیص، گفته‌های هدف هم با مدل کلیدواژه و هم با مدل فیلتر هم‌تراز و بر اساس هزینهٔ هم‌ترازی در مورد آنها تصمیم‌گیری می‌شود. در [15]، [16] از مدل‌های مخفی مارکوف (HMM)^۳ برای مدل کردن کلیدواژه‌ها و فیلترها استفاده شده است و با جستجو درون یک گراف رمزگشاشده که در آن کلیدواژه‌ها و فیلترها هم‌زمان ظاهر می‌شوند، تشخیص انجام می‌شود. پژوهش‌های اخیر در این زمینه کمابیش این چارچوب را همراه با تمرکز بر مدل کردن واژگان فیلتر [26] و روش امتیازدهی پیشرفته [27]، دنبال می‌کنند. روش‌های آموزش تمایزی^۴ [28] نیز در این زمینه مورد بررسی قرار گرفته‌اند تا به‌طور مستقیم کارایی کلیدواژه‌ها را بهینه کنند.

۲-۳- روش‌های بازشناسی گفتار پیوسته با واژگان بزرگ

روش‌های بازشناسی گفتار پیوسته با واژگان بزرگ (LVCSR)^۵ در همین اواخر برای کاربردهایی مانند

نمایه‌گذاری صدا و داده‌کاوی گفتار به‌طور گسترده استفاده شده‌اند. در این رویکرد، گفته‌ها توسط سامانه بازشناسی گفتار به واژه‌ها بازشناسی، برای جستجوی کارآمد نمایه و بر روی نمایه‌ها جستجو انجام می‌شود [5]. درواقع در این روش، سامانه LVCSR و سامانهٔ جستجوگر باهم متوالی می‌شوند و سامانهٔ جستجوگر بر روی خروجی بازشناسی شده جستجو انجام می‌دهد. در سال‌های اخیر، با این رویکرد بر روی زبان‌هایی با منابع محدود تمرکز شده است. زبان‌های با منابع آموزشی محدود، با حداکثر چهل ساعت سند آموزشی گفتاری مانند پشتو و گرجی، هستند [6]-[8]. در پروژهٔ IARPA babel [29] نیز مجموعه‌ای از زبان‌های محدود جمع‌آوری شده است.

به‌کارگیری بازشناسی گفتار در تشخیص عبارت گفتاری اگرچه بسیار رایج است، اما چالش‌های مختلفی دارد. نخستین چالش در این روش، خروجی غیرقطعی و دارای خطای سامانهٔ بازشناسی گفتار است. نخستین بهترین^۶ فرضیه در سامانه‌های بازشناسی گفتار به‌طور معمول شامل خطاهایی هستند که عملکرد تشخیص را دچار مشکل می‌کنند. برای عملکرد بهتر، به‌طور معمول شبکه درهم‌ریختگی^۷ یا موقعیت خاص پسین مشبک^۸ [30] و زمان تدریجی مشبک^۹ [31] یا مشبک^{۱۰} [32] به‌جای نخستین بهترین فرضیه‌ها برای شاخص‌گذاری تولید می‌شوند. یکی از روش‌ها برای غلبه بر این مشکل، ندیدن دو سامانهٔ بازشناسی و شاخص‌گذار به‌صورت مجزا است؛ درواقع باید ترکیب متوالی این دو سامانه را به‌عنوان یک سامانه در نظر گرفت. در [1] پنج روش کلی را برای دیدن یک‌جای این سامانه‌ها معرفی کرده و مورد بحث قرار داده شده است. در [5] خلاصه‌ای از کنفرانس‌هایی با موضوع بازیابی اسناد گفتاری در اخبار پخش همگانی^{۱۱} در سال ۲۰۰۰ آمده است که رویکرد این پژوهش‌ها به‌کارگیری روش‌ها و سامانه‌های بازشناسی گفتار و بازیابی متون به‌صورت متوالی برای حل این مسأله بوده است. در این مقاله عنوان شده که عملکردی مشابه نتایج انسانی در بازیابی اسناد گفتاری به‌دست آمده است که برای رسیدن به این نتایج سامانهٔ بازشناسی گفتار نرخ خطای واژه (WER)^{۱۲} بین ۱۵ الی ۲۰ درصد باید داشته باشد، که از دقت رونوشت‌های دستی زیاد فاصله ندارد.

⁶ 1-best

⁷ Confusion network

⁸ Position specific posterior lattices

⁹ Time-quantized lattices

¹⁰ Lattice

¹¹ Broadcast

¹² Word Error Rate (WER)

¹ Utterance

² Dynamic Time Warping (DTW)

³ Hidden Markov Model (HMM)

⁴ Discriminative

⁵ Large vocabulary continuous speech recognition (LVCSR)

به اختصار برای مقایسه نقاط قوت و ضعف روش‌های اشاره‌شده در بالا، به موارد زیر می‌شود اشاره کرد:

در روش‌های پرسش با مثال و کلیدواژه/فیلتر نیاز به مجموعه‌ای از صوت‌ها حاوی واژه جستجو داریم، مجموعه کلیدواژه‌های مورد جستجو محدود هستند و باید از قبل مشخص باشند؛ ولی این روش‌ها سرعت بیشتر و محاسبات کمتر نسبت استفاده از سامانه بازشناسی گفتار دارند؛ روش کلیدواژه/فیلتر دقت بیشتری نسبت به روش پرسش با مثال دارد.

در روش بازشناسی گفتار نیاز به یک سامانه بازشناسی گفتار است؛ این سامانه‌ها به‌طور معمول پیچیده و دارای محاسبات زیادی هستند؛ درضمن آموزش آن‌ها زمان‌بر و پرهزینه است؛ ولی با استفاده از سامانه بازشناسی گفتار مجموعه کلیدواژه‌ها دامنه بیشتری را دارند (روش‌های پرسش با مثال و کلیدواژه/فیلتر حداکثر چند ده تا چند صد کلیدواژه را در بردارند؛ ولی سامانه‌های بازشناسی گفتار قابلیت بازشناسی تا حدود چندمیلیون واژه را دارند)؛ هرچند واژه‌های خارج واژگان قابل شناسایی برای سامانه بازشناسی گفتار نیستند، ولی روش‌هایی برای مقابله با این مسأله ارائه شده است. در روش‌های پرسش با مثال و کلیدواژه/فیلتر برای اضافه کردن یک کلیدواژه جدید نیاز به بازطراحی ولی در سامانه‌های بازشناسی گفتار با طراحی اولیه قابلیت جستجوی بسیاری از کلیدواژه‌ها است. در این پژوهش با توجه به بازبودن دامنه کلیدواژه‌ها از سامانه بازشناسی گفتار استفاده شده است. درضمن سامانه بازشناسی گفتار اطلاعات بیشتری از محتوای صوت تولید می‌کند (متن صوت را تولید می‌کند) که برای نمایش دادن به کاربر و طبقه‌بندی اطلاعات و اسناد مفید است.

۴-۲- کارهای انجام گرفته روی زبان فارسی

در زبان فارسی پژوهش‌های کمی بر روی تشخیص عبارات گفتاری انجام شده است. بر طبق جستجوهای انجام گرفته توسط پژوهشگران این مقاله، در [9]، [34]-[38] از رویکرد به کارگیری بازشناسی گفتار برای تشخیص عبارتهای گفتاری در زبان فارسی استفاده شده است. مقاله‌ها و پژوهش‌های دیگری با رویکردهای متفاوت و عدم به کارگیری بازشناسی گفتار انجام شده‌اند [42].

یکی دیگر از معایب روش‌های تشخیص کلیدواژه بر پایه بازشناسی گفتار، وجود کلیدواژه‌های خارج از واژگان (OOV) است. واژگان و لغت‌نامه سامانه‌های بازشناسی گفتار به‌طور معمول از قبل تعریف شده هستند و اگر یک کلیدواژه خارج از واژگان سامانه باشد، راهی برای اینکه سامانه بتواند چیزی در مورد آن کلیدواژه ارائه کند، وجود ندارد. برای غلبه بر این چالش، یکی از روش‌ها، استفاده از زیرواژه‌ها^۱ است. واحدهای زیرواژه‌ها می‌توانند واج، هجا و یا قطعه‌واژه باشند. مشبک‌های زیرواژه می‌توانند با استفاده از واژگان زیرواژه همراه با مدل‌های زبانی زیرواژه‌ای تولید شوند. همچنین می‌توان مشبک‌ها در سطح واژه را به‌طور مستقیم به مشبک‌های زیرواژه‌ها تبدیل شوند. بعد از این که مشبک‌های زیرواژه به وجود آمدند می‌توان بر روی دنباله زیرواژه‌ها جستجو انجام شود [25]، [26]. در [2] روش‌های ارائه شده مبتنی بر زیرواژه‌ها و انواع آن‌ها در زبان‌های مختلف به‌طور مفصل تری بحث شده‌اند. یکی دیگر از روش‌های پیشنهادشده برای حل مشکل کلیدواژه‌های OOV، روش واژه‌های نماینده^۲ [31] است. واژه‌های نماینده، واژه‌هایی هستند که شباهت آوایی با کلیدواژه OOV دارند. این روش بر پایه مبدل‌های حالت محدود وزنی است و در آن با استفاده از واژه‌های واژگان سامانه بازشناسی گفتار واژه‌هایی با شباهت آوایی متناسب با کلیدواژه OOV ساخته می‌شود.

ساختار اسناد گفتاری یکی دیگر از چالش‌ها است. این چالش در اسناد گفتاری بلند مانند پردازش اسناد مربوط به بایگانی، بیش تر مربوط می‌شود. در این حالت ممکن است یک سند گفتاری شامل موضوعات مختلف، بافت و زمینه‌های مختلف باشد.

چالش دیگر رابط کاربری سامانه است. در سامانه‌های جستجوی مبتنی بر متن قسمتی از متن برای کاربر نوشته می‌شود و کاربر می‌تواند سریع نتایج را بررسی کند؛ ولی در این سامانه‌ها رابط کاربری باید چگونه باشد؟ و کاربر چه‌طور می‌تواند نتایج را بررسی کند؟ در [1]، [2]، [27] در مورد این چالش بیش تر بحث شده است.

چالش‌های دیگری مانند سرعت جستجو، دقت جستجو و حجم خروجی شاخص گذاری شده نیز می‌توانند مطرح شوند [36].

¹ Subword

² Proxy words

(جدول-۱): خلاصه‌ای از پژوهش‌های پیشین بر روی زبان‌های مختلف.

(Table-1): Summary of related works on different languages.

زبان	دادگان	روش	ATWV
انگلیسی [3]	گفتار تلفنی محاوره‌ای	ASR	0.8335
	اخبار پخش همگانی	ASR	0.8485
	اتاق‌های میزگرد گفتگو	ASR	0.2553
اسپانیایی [4]	MAVIR database	ASR	0.6404
	EPIC	ASR	0.9362
منابع محدود	۲۳ ساعت از زبان‌های منابع محدود مانند آلمانی، اسلوواکی، چک، رومانی، به‌صورت زبان محاوره‌ای و اخبار همگانی	پرشش-با-نمونه DTW [7]	0.58
	IARPA BABEL [29]	ASR-kaldi [6]	0.705
		ASR- BBN[8]	0.739
فارسی	فارس‌دات بزرگ [44]	ASR[9]	0.85
	فارس‌دات کوچک [43]	ASR-proxy [9]	0.2
	فارس‌دات تلفنی [45] و دادگان تلفنی بانک	phone search & WFST [38]	0.8

این دو نمایه جستجو می‌شوند و از روش واژه‌های نماینده برای بهبود کلیدواژه‌های OOV استفاده شده است. در این پژوهش از دادگان فارس‌دات بزرگ [44] استفاده شده و به نرخ خطای واژه ۰/۲ درصد بر روی فارس‌دات بزرگ رسیده و برای تشخیص عبارت‌های گفتاری با معیار ارزش بیشینه وزنی عبارت (MTWV)^۴ عدد ۰/۸۳ فقط با جستجو بر روی نمایه واژه، عدد ۰/۳۹ فقط با جستجو بر روی نمایه واجی و عدد ۰/۸۵ با ترکیب این دو جستجو حاصل شده است.

در [38] عباسیان روش‌های مبتنی بر رشته واج و جستجو مبتنی بر مشبک واج را بر روی زبان فارسی پیاده‌سازی کرده است. در جستجوی مبتنی بر رشته واج ابتدا گفتار به یک رشته واج بازنشانی می‌شود؛ سپس با استفاده از فاصله لونشتاین^۵، فاصله رشته واج بازنشانی شده با رشته واج کلیدواژه مقایسه می‌شود. در جستجوی مبتنی بر مشبک واج، بعد از بازنشانی گفتار به مشبک واج، بر روی آن جستجو انجام می‌شود. این پژوهش بر روی دادگان فارس‌دات تلفنی [45] و دادگان تلفنی بانکی انجام شده و به‌دقت ۸۳ درصدی برای بازنشانی واج با روش شبکه حافظه کوتاه‌مدت ماندگار دوسویه^۶ رسیده است. تعداد کلیدواژه‌های این پژوهش چهارده کلیدواژه پرتکرار بوده و در بهترین حالت به ۰/۸ برای معیار ATWV رسیده است.

در [9] گمار پژوهشی را بر روی تشخیص عبارت‌های گفتاری بر پایه بازنشانی گفتار و شرایط محدود، انجام داده است. در این پژوهش با آموزش یک شبکه گلوگاهی عصبی^۱ دقت بازنشانی واج را بالا برده و عملکرد تشخیص عبارت‌های گفتاری را بهبود داده است. برای بهبود عملکرد از گسترش دایره واژگان برای واژه‌های نماینده استفاده کرده است. در این پژوهش همه سه حرفی‌های فارسی ساخته شده و تلفظ آن‌ها با روش‌های نویسه به واج تولید شده است. این پژوهش بر روی دادگان فارس‌دات کوچک [43] انجام شده است و ۱۷۰ کلیدواژه تک‌واژه‌ای استفاده شده است که ۹۸ کلیدواژه درون واژگان بازنشانی گفتار (INV)^۲ و ۷۲ کلیدواژه OOV بوده‌اند. این سامانه به نرخ خطای واژه ۴۹٪ رسیده است. برای تشخیص عبارت‌ها با معیار ارزش وزنی واقعی عبارت (ATWV)^۳ عدد ۰/۲ با استفاده از واژه‌های نماینده و عدد ۰/۳ با گسترش واژگان بازنشانی گفتار حاصل شده است. با توجه به حجم کم دادگان فارس‌دات کوچک هم برای آموزش و هم برای آزمون و حجم بالای واژه‌های OOV (حدود ۴۲٪) به نظر نتایج خوبی به‌دست آمده است.

غذیری‌نیا در [37] بر اساس تشخیص واجی و واژه‌ای سامانه‌ای را برای تشخیص عبارت‌های گفتاری فارسی طراحی کرده است. در این سامانه اسناد گفتاری در دو سطح واژه و واج نمایه‌گذاری می‌شوند و کلیدواژه بر روی هر دوی

⁴ Maximum Term Weighted Value (MTWV)

² Levenshtein Distance


³ Bidirectional Long Short-Term Memory (BLSTM)

¹ Bottleneck neural network

² IN-Vocabulary (INV)

³ Actual Term Weighted Value (ATWV)

تصمیم دوگانه (بله یا خیر) برای این که آیا سامانه رخداد فرضی را قبول دارد یا خیر؟ و یک امتیاز تشخیص که نشان دهنده میزان واقعی اتفاق عبارت احتمالی است. این تصمیم گیری، تصمیم گیری «واقعی» نامید می شود. در ادامه این بخش به روش پیشنهادی این مقاله برای تشخیص عبارتهای گفتاری پرداخته می شود.



(شکل-۱): ساختار کلی سامانه‌های تشخیص عبارتهای گفتاری

بر پایه‌ی بازشناسی گفتار

(Figure-1): Overall Structure of an STD based on ASR

۳-۲- روش پیشنهادی

در این مقاله برای تشخیص عبارتهای گفتاری از سامانه بازشناسی گفتار استفاده شده است. در ابتدا سامانه بازشناسی گفتار برای زبان فارسی طراحی و پیاده سازی شده است. در ادامه مجموعه صوت‌ها و گفتارها توسط سامانه بازشناسی گفتار به متن بازشناسی می شوند.

در این مرحله از آنجایی که نخستین بهترین خروجی بازشناسی گفتار دارای خطا است، از مشبک خروجی سامانه بازشناسی گفتار که گرافی از تمام واژه‌های احتمالی بازشناسی شده است، استفاده می شود؛ سپس برای نمایه کردن خروجی بازشناسی گفتار، مبدل‌های حالت محدود به کاررفته گرفته شده‌اند. این روش از سرعت و حجم محاسباتی قابل قبولی برخوردار است [46]. در مرحله جستجوی کلیدواژه، اگر کلیدواژه در دایره واژگان سامانه بازشناسی گفتار وجود داشته باشد، کلیدواژه به طور مستقیم بر روی نمایه‌ها جستجو می شود؛ اما اگر کلیدواژه از واژه‌های خارج از دایره واژگان سامانه بازشناسی گفتار باشد، از روش واژه‌های نماینده [31] استفاده می شود. در این روش از روی واژگان سامانه بازشناسی گفتار، واژه‌های مشابه آوایی برای جستجوی کلیدواژه‌های OOV ساخته و از آن‌ها برای جستجو بر روی نمایه‌ها استفاده می شود. از آنجایی که در این

صرفجو در [39] با استفاده از سامانه بازشناسی گفتار بر روی اسناد گفتاری، بازیابی انجام داده است. در این پایان نامه با هدف مقابله با خطای خروجی سامانه بازشناسی گفتار، برای هر واژه مهم موجود در سند، تعدادی کلمه مشابه در نظر گرفته می شود. به این ترتیب به ازای هر سند، تعدادی سند جایگزین به دست می آید. با توجه به تعداد زیاد اسناد جایگزین، در مرحله بعد، مؤثرترین اسناد جایگزین، انتخاب و این اسناد جایگزین، به اسناد فعلی اضافه و در نهایت الگوریتم بازیابی روی مجموعه جدید اسناد اعمال می شود.

اخلاقی و سلطانی در [37]، [38] نیز بر پایه متن خروجی بازشناسی گفتار بر روی بازیابی اسناد گفتاری متمرکز شده‌اند. در این پژوهش‌ها سعی در تشخیص خطای بازشناسی در واژه‌های بازشناسی شده و در نظر گرفتن واژه‌های مشابه برای واژه‌های دارای خطا، بوده است.

۳- روش پیشنهادی

۳-۱- مبانی تشخیص عبارتهای گفتاری

سامانه‌های تشخیص عبارتهای گفتاری، بر اساس بازشناسی گفتار از دو مرحله تشکیل شده‌اند؛ ۱- بازشناسی مجموعه سندهای صوتی و گفتاری و ۲- نمایه کردن و جستجو در نتایج بازشناسی گفتار. در واقع قبل از جستجو، باید مجموعه اسناد نمایه شوند و در مرحله نمایه کردن، اطلاعاتی از عبارتهای مورد جستجو وجود ندارد و نمی توان از آن‌ها استفاده کرد. بخش‌های اصلی سامانه‌های تشخیص عبارتهای گفتاری بر اساس سامانه‌های بازشناسی گفتار در شکل (۱) نشان داده شده است.

عبارت‌ها دنباله‌ای از واژه‌های گفتاری هستند که ارتباط زبانی با یکدیگر ندارند، بلکه گستره دستور زبانی دارند و می توانند از واژگان منفرد تا گروه واژه^۱ باشند. عبارت‌ها باید یک معنی به طور کامل قابل تشخیص داشته باشند به صورتی که یک کاربر فرضی تمایل به پیدا کردن آن‌ها داشته باشد. عبارت‌ها شامل پنج یا کمتر واژه هستند. عبارت‌ها فقط به صورت نوشتاری هستند و سامانه باید تفاوت تلفظی آن‌ها را در املا ی یکسان در نظر بگیرد.

برای هر رخداد محتمل از عبارت مورد جستجو، سامانه باید خروجی‌هایی شامل موارد زیر را گزارش کند: شروع و پایان زمان رخداد عبارت در سند مربوطه، یک

^۱ phrase

روش کلیدواژه‌ها بازنمایی می‌شوند، دیگر نیازی به نمایه‌گذاری جدا نیست. با توجه به مشابهت آوایی واج‌ها روش‌های جستجوی کلیدواژه‌های OOV داری هشدار نادرست زیادی هستند، برای بهبود این روش از یک شبکه‌انتهای LSTM-CTC استفاده می‌شود [47]. این شبکه بر اساس بازشناسی نویسه به جای واج است و برای شناسایی OOV‌ها (به‌طورمعمول آوای OOV‌ها موجود نیست ولی نوشتار آن‌ها موجود است) مناسب‌تر هست. همچنین این شبکه بر اساس واژه‌های جدا از هم (نه گفتار پیوسته) آموزش داده و باعث می‌شود اثر مدل زبانی را در بازشناسی کمتر می‌کند.

در ادامه به مبانی این روش‌ها پرداخته می‌شود. جزئیات این روش‌ها، طریقه پیاده‌سازی، الگوریتم‌ها و مشخصات محاسباتی آن‌ها و نتایج بر روی دادگان مختلف در مقاله‌های مرجع آن‌ها آمده است.

۳-۳- الگوریتم تشخیص

همان‌طور که اشاره شد، نخستین‌بهترین خروجی بازشناسی‌شده دارای خطا است و این خطا بر روی فرایند تشخیص عبارت‌ها تأثیرگذار است. همان‌طور که در [5] عنوان شده است، با سامانه بازشناسی گفتار با حدود بیست درصد خطا می‌توان به‌دقت انسانی در بازیابی اطلاعات دست‌یافت. برای مقابله با عدم قطعیت در خروجی بازشناسی گفتار به جای جستجو بر روی نخستین‌بهترین خطای بازشناسی‌شده، بر روی مشبک خروجی آن جستجو انجام می‌شود. مشبک خروجی یک گراف‌های بدون دور جهت‌دار وزن‌دار است که همه احتمال‌های خروجی بازشناسی‌شده را نمایش می‌دهد. با توجه به حفظ تمام احتمالات در مشبک روش پیشنهادی باید از حجم و زمان محاسباتی معقولی برخوردار باشد.

برای تطبیق رشته در متن، از الگوریتم مبدل عامل [10] استفاده می‌شود. مراحل تولید این مبدل از روی یک ماشین خودکار^۱ مربوط به متن در [10] شرح داده شده است. این روش ماشین خودکار عامل نامیده شده است. ماشین خودکار عامل $F(u)$ یک رشته u یک پذیرنده حالت محدود کمینه و قطعی است که مجموعه زیررشته‌های u را عیناً و به‌درستی بازشناسی می‌کند. درواقع مبدل عامل یک رشته مانند ABCD هر زیررشته از آن را (مانند A, AB, CD) پذیرش یا بازشناسی می‌کند.

^۱ Automata

در الگوریتم جستجو سعی بر این است که مشبک^۲ خروجی ASR که با یک ماشین خودکار نمایش داده می‌شود، به یک مبدل عامل تبدیل شود تا بتوان بر روی آن جستجو انجام داد [46]. البته به‌طورکلی این مسأله با جستجو بر روی متن متفاوت است؛ زیرا برخلاف متن، خروجی ASR به‌صورت غیرقطعی است. در این روش مبدل حالت محدود وزنی مشبک‌های همه گفته‌ها در مجموعه جستجو از مبدل‌های حالت محدود وزنی اختصاصی، به یک ساختار مبدل عامل تبدیل می‌شود؛ که در آن زمان شروع، زمان پایان و مشبک احتمالات پسین هر قطعه واژه را به‌صورت یک هزینه‌های سه‌بعدی ذخیره می‌کند. این مبدل عامل درواقع یک نمایه‌گذاری وارون از همه رشته‌واژگان در مشبک خروجی بازشناسی گفتار است.

بعد از نمایه‌کردن تمام اسناد گفتاری، جستجوی درخواست کاربر بر روی آن انجام می‌شود. درخواست کاربر به‌طورمعمول یک رشته‌ی بدون وزن است ولی می‌توان آن را به‌صورت یک ماشین خودکار وزنی دلخواه در نظر گرفته شود. این کار عبارت‌های منظم را که می‌توانند به ماشین خودکار تبدیل شوند؛ پوشش می‌دهد. با هم‌نهشت کردن^۳ ماشین خودکار وزنی درخواست با نمایه‌ها (که به‌صورت ماشین خودکار وزنی ذخیره شده‌اند) در قسمت ورودی جستجو انجام می‌پذیرد.

۴-۳- واژه‌های نماینده

همان‌طور که بیان شد، یکی از چالش‌های تشخیص عبارت‌های گفتاری مبتنی بر بازشناسی گفتار کلیدواژه‌های خارج از واژگان (OOV) است که برای مقابله با این چالش، در [31] روش واژه‌های نماینده معرفی شده است. ایده اصلی این روش از روش گسترش پرسش در بازیابی متن گرفته شده است. در گسترش پرسش، یک پرسش را با واژه‌ها یا اصطلاحات مشابه آن پرسش در معنا یا شکل واژگانی مانند مترادف‌ها یا انواع ساخت‌واژی^۴ تکمیل و تقویت و بر اساس همین ایده، برای جستجوی یک پرسش، آن را با کلیدواژه‌های مشابه آوایی آن جستجو می‌کنند. به این واژه‌های مشابه آوایی، واژه‌های نماینده می‌گویند. روش واژه‌های نماینده، روشی بر اساس مبدل‌های حالت محدود وزنی هستند که در آن مبدل‌های مشابه آوایی برای کلیدواژه OOV از روی INV ساخته می‌شود.

^۲ Lattice

^۳ compos

^۴ Morphological


جامع آوایی برای تصدیق خروجی روش واژه‌های نماینده است. روش تصدیق، ویژگی قطعه‌ها را متناسب با دنباله حروف هم‌تراز می‌کند و احتمال پیشین آن را به‌عنوان امتیاز اطمینان در نظر می‌گیرد.

در [47] نشان داده شده است که شبکه‌های دسته‌بندی زمانی پیوندگرا (CTC) بسیار مناسب برای برچسب‌زنی این‌چنین دنباله داده‌های بدون قطعه‌بندی هستند. با در نظر گرفتن یک دنباله ویژگی ورودی X به طول T و دنباله حروف آن W ، CTC یک تابع هدف است که به شکل زیر تعریف می‌شود:

$$L_{CTC}(X, W) = \sum_{c \in W} p(c|X) = \sum_{c \in W} \prod_{t=1}^T p(c_t|X) \quad (2)$$

که Cw هر دنباله برچسب با طول T متناسب با دنباله درست حروف W است. با جمع‌بستن بر روی تمامی مجموعه محل‌های برچسب که دنباله یکسان W را حاصل می‌کند، CTC یک توزیع احتمالی بر روی برچسب‌زنی‌های ممکن مشروط به دنباله ورودی X ، را تعیین می‌کند.

در این روش، یک لایه CTC در بالای شبکه عصبی LSTM قرار داده شده است که به‌طور مستقیم با استفاده از ویژگی گفتار اصلی آموزش داده می‌شود. در مرحله آموزش، نمونه‌های واژه‌ای (نه به‌صورت جمله پیوسته) به یک شبکه چندلایه LSTM که از معیار CTC استفاده می‌کند، داده می‌شود. برای آماده کردن نمونه‌های واژه‌ای از صوت‌ها، از سامانه بازشناسی گفتار برای هم‌ترازی واژه‌ها در سطح گفته‌ها استفاده می‌شود. در مرحله آزمون، نمونه‌های کشف‌شده واژه‌های نماینده به یک شبکه عصبی LSTM وارد می‌شود و امتیاز تصدیق خروجی هستند. سامانه تصدیق LSTM-CTC در شکل (۲) نشان داده شده است.



(شکل ۲): تصدیق کننده LSTM-CTC. مرحله

آموزش و آزمون [47].

(Figure-2): LSTM-CTC verification. Train and test phases [47].

فرض کنید K بیانگر یک پذیرنده حالت محدود برای یک کلیدواژه OOV و L_2 یک مبدل حالت محدود برای تلفظ کلیدواژه OOV باشد؛ E را یک مبدل ویرایش فاصله فرض کنید که یک رشته واج را به هر دنباله واجی دیگر با هزینه‌های تخمینی از یک ماتریس درهم‌ریختگی نگاشت می‌کند؛ همچنین L_1 را واژگان سامانه بازشناسی گفتار در نظر بگیرید؛ روش WFST برای تولید کلیدواژه نماینده K' با عبارت زیر توصیف می‌شود:

$$K' = Project(ShortestPath(K \circ L_2 \circ E \circ (L_1^*)^{-1})). \quad (1)$$

در روش جستجوی کلیدواژه‌های dNV، عبارت جستجو به‌صورت یک مبدل حالت محدود بازنمایی می‌شود و با هم‌نهشتی بر روی نمایه‌ها (ذخیره‌شده به‌صورت یک مبدل حالت محدود) جستجو انجام می‌گردد. در روش واژه‌های نماینده، عبارت شماره (۱) مبدل حالت محدود وزنی واژه OOV را می‌سازد. این مبدل حالت محدود وزنی یک فاصله‌یاب بین واژه‌های داخل واژگان ASR و آوای تولیدی واژه OOV است، برای تخمین فاصله از ماتریس درهم‌ریختگی واج‌ها استفاده می‌شود.


یکی از مزیت‌های این روش، عدم ذخیره نمایه‌گذاری جداگانه (مثل نمایه‌های واجی) برای کلیدواژه‌های OOV است، این کلیدواژه‌ها از نمایه‌های کلیدواژه‌های IV استفاده می‌کنند.

یکی از ضعف‌های عمومی روش‌های مرتبط با OOVها بالابودن هشدار نادرست در خروجی آن‌ها است. هشدارهای نادرست به‌علت متکی بودن این روش‌ها به بازشناسی واج است. برای همین روش‌هایی برای مقابله با این مشکل ارائه شده است [48] که در زیر یک روش برای بازتخمین خروجی واژه‌های نماینده بیان می‌شود.

۱-۴-۳- بهبود عملکرد روش واژه‌های نماینده

روش‌های جستجو برای عبارت‌های OOV به‌طور معمول دارای هشدار نادرست زیادی هستند. در اینجا یک روش برای بهبود عملکرد واژه‌های نماینده ارائه شده است. ایده اصلی این روش بازتخمین امتیاز خروجی‌های روش واژه‌های نماینده با استفاده از یک شبکه حافظه کوتاه‌مدت ماندگار و دسته‌بندی زمانی پیوندگرا (LSTM-CTC) است [47].

هدف اصلی در این روش، محاسبه دوباره امتیاز اطمینان برای خروجی واژه‌های نماینده است. ایده اصلی این روش استفاده از یک شبکه LSTM-CTC به‌عنوان یک مدل



(شکل-۳): روندنمای کلی سامانه تشخیص عبارت‌های گفتاری پیشنهادی

(Figure-3): Proposed flowchart for spoken term detection

واژگان سامانه بازنشاسی گفتار انتخاب می‌شود. واژه‌های انتخاب‌شده به جای کلیدواژه خارج از دادگان بر روی نمایه‌ها جستجو می‌شود.

یکی از مزیت‌های روش واژه‌های نماینده عدم نیاز به نمایه دیگری مانند نمایه واجی است. در این روش واژه‌های نماینده به جای کلیدواژه‌های خارج از واژگان سامانه بازنشاسی، مستقیم بر روی نمایه‌های واژه جستجو می‌شوند. این مزیت باعث کم‌شدن حجم محاسبات و عدم نیاز به ذخیره نمایه جداگانه می‌شود.

از آنجایی که روش واژه‌های نماینده از شباهت واجی بین کلیدواژه خارج از واژگان و واژگان سامانه بازنشاسی استفاده می‌کند، به علت شباهت آوایی بین برخی واج‌ها، دارای هشدارهای نادرست زیاد است. برای مقابله با این هشدارهای نادرست یک شبکه LSTM-CTC برای تخمین دوباره امتیاز اطمینان خروجی واژه‌های نماینده پیشنهاد شده است. یکی از مزیت‌های شبکه LSTM-CTC بازنشاسی گفتار بر اساس نویسه به جای واج است. از آنجایی که تلفظ واژه‌های خارج از واژگان در دسترس نیست و با استفاده از شبکه‌های نویسه به واج ایجاد می‌شود، به طور معمول این تلفظ‌ها دارای خطا هستند؛ بنابراین بازنشاسی نویسه در شبکه‌های LSTM-CTC این خطا را از بین می‌برد.

علاوه بر مشکل شباهت واجی در روش واژه‌های نماینده، عدم امتیازدهی به واژه‌های خارج از دادگان در رمزگشایی بازنشاسی گفتار، مشکل‌زا است. در رمزگشایی سامانه بازنشاسی گفتار هر دو، وزن مدل آوایی و وزن مدل زبانی مهم هستند. به طور معمول وزن واژه‌های خارج از دادگان در مدل زبانی حذف و این باعث می‌شود، برخلاف داشتن وزن مدل آوایی برای واژه‌های خارج از دادگان، ولی در مدل زبانی وزنی نداشته باشند.

۵-۳- شمای کلی روش

شمای کلی روش پیشنهادی در شکل (۳) آمده است. این سامانه از دو زیرسامانه بازنشاسی گفتار و تشخیص عبارت‌ها تشکیل شده است. ابتدا سامانه بازنشاسی گفتار اسناد گفتاری ورودی را به مجموعه‌ای واژگان که در قالب شبکه‌ها نگهداری می‌شوند، تبدیل می‌کند. شبکه‌های حاصل، به عنوان ورودی به زیرسامانه تشخیص وارد و در این زیرسامانه ابتدا شبکه‌ها نمایه‌گذاری می‌شوند. برای این کار، تمام واژه‌هایی که در این شبکه‌ها بازنشاسی شده‌اند، به صورت یک سه‌تایی (احتمال پسین، زمان شروع، زمان پایان) نمایه می‌شوند. احتمال پسین به عنوان امتیاز اطمینان نمایه‌ها استفاده می‌شود.

در بخش جستجو از دو روش متفاوت برای جستجوی کلیدواژه‌های درون واژگان و خارج از واژگان استفاده می‌شود. اگر کلیدواژه ورودی در واژگان سامانه بازنشاسی گفتار وجود داشته باشد، این کلیدواژه مستقیم بر روی نمایه‌ها جستجو و تشخیص‌های احتمالی به تصمیم‌گیرنده وارد می‌شود. تصمیم‌گیرنده بر اساس امتیازهای نمایه‌ها و یک مرز تصمیم، تشخیص‌های احتمالی را پذیرش یا رد می‌کند.

در صورتی که کلیدواژه در واژگان سامانه بازنشاسی وجود نداشته باشد، با استفاده از واژه‌های نماینده مبدل‌های حالت محدود وزنی، مشابه آوایی آن از روی واژگان بازنشاسی گفتار ساخته می‌شود و این مبدل‌های نماینده بر روی نمایه‌ها مورد جستجو قرار می‌گیرد. در این روش ابتدا تلفظ کلیدواژه خارج از واژگان ایجاد، سپس با استفاده از ماتریس درهم‌ریختگی واج، شباهت آوایی بین تلفظ کلیدواژه و واژگان سامانه بازنشاسی محاسبه و شبیه‌ترین واژه‌ها به

در این روش، شبکه LSTM-CTC به صورت واژه به واژه (و نه به صورت پیوسته) آموزش داده می شود. به علت آموزش واژه به واژه، وزن مدل زبانی (دنباله واژه ها) در مرحله رمزگشایی تأثیر به سزایی ندارد و بیشتر مدل آوایی در آن تأثیرگذار است. تأثیر کم وزن مدل زبانی در رمزگشایی، یکی دیگر از مزیت های این روش آموزش است. در اینجا بیشتر امتیاز مدل آوایی تأثیرگذار است.

در مرحله آزمون، تشخیص های روش واژه های نماینده برای بازشناسی به شبکه LSTM-CTC داده می شود و شبکه این تشخیص ها را دوباره بازشناسی می کند و برای آن ها امتیاز اطمینان دوباره محاسبه می شود. این امتیاز اطمینان به عنوان امتیاز جدید تشخیص ها استفاده و به تصمیم گیرنده داده می شود. تصمیم گیرنده بر اساس مرز تصمیم درباره پذیرش یا رد آن ها تصمیم گیری می کند.

۴- ارزیابی و نتایج

۴-۱- دادگان

در این پژوهش تمرکز بر روی زبان فارسی است و از سه پایگاه داده استفاده شد. پایگاه داده فارسی دات کوچک [43]، فارسی دات بزرگ [44] و پایگاه داده دادگان اخبار فارسی صداوسیما جمهوری اسلامی ایران^۱ در این پژوهش است.

پایگاه داده فارسی دات کوچک: در این دادگان، ۳۰۴ گوینده به صورت اتفاقی بیست جمله را می خوانند. در مجموع ۴۵۰ جمله استفاده شده است، که هر گوینده هجده جمله را به صورت اتفاقی می خواند و دو جمله را همه گویندگان خوانده اند. جمله ها مصنوعی ساخته شده اند به دلیل این که تنوع آوایی زبان فارسی پوشش داده شود. گویندگان از مناطق مختلف ایران انتخاب شده اند و در مجموع، دادگان از ده لهجه عمومی فارسی تشکیل شده است. نسبت مردان به زنان ۲:۱ است. دادگان در محیط کم نوفه با میانگین سیگنال به نوفه حدود ۳۱ dB و نرخ نمونه برداری ۲۲۰۵۰ HZ ضبط شده اند. این دادگان در سطح واج تقطیع و برچسب گذاری شده اند. فارسی دات کوچک را می توان با دادگان TIMIT [49] در زبان انگلیسی مقایسه کرد. این دادگان در مجموع حدود پنج ساعت است.

^۱ این دادگان از طریق دکتر باقر باباعلی عضو هیئت علمی دانشگاه تهران، دانشکده دانشکده ریاضی، آمار و علوم رایانه تهیه شد. مقاله مرجع خاصی برای ارجاع دهی ندارد.

پایگاه داده فارسی دات بزرگ: فارسی دات بزرگ در مجموع ۱۴۰ ساعت سیگنال گفتار است که تقطیع و برچسب گذاری در حد واژه شده اند. تعداد ۱۰۰ گوینده (۳۹ زن و ۶۱ مرد) با لهجه رایج فارسی و هر گوینده ۲۰-۲۵ صفحه متن با موضوعات مختلف را خوانده اند. برخلاف فارسی دات کوچک که در محیط ساکت و بدون اعوجاج^۲ ضبط شده است، فارسی دات بزرگ در محیط اداری و دفتر کار ضبط شده است. چهار میکروفن، یک میکروفن رومیزی یک سویی، دو میکروفن یقه ای و یک میکروفن گوشی برای ضبط سیگنال گفتار استفاده شده است. همه سیگنال های گفتاری هم زمان با دو میکروفن ضبط شده اند؛ میکروفن رومیزی در ضبط همه سیگنال ها استفاده شده و سه میکروفن دیگر هر کدام در یک سوم دادگان استفاده شده است.

دادگان اخبار فارسی صداوسیما جمهوری

اسلامی ایران: این پایگاه داده حدود سی ساعت اخبار فارسی پخش شده از سیمای جمهوری اسلامی ایران را در حد جمله تقطیع و برچسب گذاری کرده است. این دادگان شبیه واقعیت و آن چیزی است که در سازمان صداوسیما تولید می شود. در این دادگان اخبار فارسی در جملات کمتر از یک دقیقه بخش بندی و فایل های صوتی آن جداگانه به همراه رونوشت متن آن تهیه شده است.

۴-۲- سامانه بازشناسی گفتار فارسی

سامانه های بازشناسی گفتار با دایره لغات وسیع، به طور معمول از سه مدل مختلف تشکیل شده اند: مدل آوایی، مدل زبانی و واژگان. در زیر به طور جداگانه حجم دادگان برای هر سه مدل توضیح داده می شود.

۴-۲-۱- مدل آوایی

پایگاه داده فارسی دات کوچک: در آزمایش های مرتبط با این دادگان، از ۲۲۴ گوینده برای آموزش مدل آوایی، ۵۰ گوینده برای توسعه و ۳۰ گوینده برای آزمون استفاده شده است [50].

پایگاه داده فارسی دات بزرگ: در این پژوهش از هفتاد ساعت دادگان میکروفن رومیزی فارسی دات بزرگ استفاده شده است. در این پژوهش، هفتاد درصد این دادگان برای آموزش مدل آوایی، هفتاد درصد برای توسعه و

^۲ Reverberation

بسیست درصد برای آزمون انتخاب شدند. آموزش شامل سی گوینده زن و ۴۳ گوینده مرد و حدود ۵۳ ساعت سیگنال گفتار؛ توسعه شامل پنج گوینده زن و یازده گوینده مرد و حدود یازده ساعت سیگنال گفتار و آزمون شامل چهار گوینده زن و هفت گوینده مرد و حدود هشت ساعت سیگنال گفتار است.

دادگان اخبار فارسی صداوسیما جمهوری

اسلامی ایران: این دادگان تجاری است و بخشی از آن با همکاری آقای دکتر باباعلی عضو هیئت علمی دانشگاه تهران فقط به عنوان آزمون در حدود سه ساعت در اختیار این پژوهش قرار گرفت. این دادگان شامل تمامی بخش های اخبار شامل گفتار رسمی گوینده، گفتارهای محاوره ای گزارش ها، محیط ها و لهجه های مختلف و گفتارها با و یا بدون موسیقی است. این دادگان شامل ۸۶۱ گفته گفتاری مجزا است.

در جدول (۲) خلاصه اطلاعات آوایی دادگان و تقسیم بندی آنها برای آموزش مدل آوایی آمده است.

۲-۲-۴- واژگان و آموزش مدل زبانی

پیکره آموزشی مدل زبانی و واژگان مرتبط برای هر دادگان به شرح زیر است:

فارسی دات کوچک: از تمامی ۴۵۰ جمله منحصر به فردی که در این دادگان به کار رفته رفته، برای ساخت مدل زبانی مورد نیاز بازشناسی گفتار استفاده شده است. این دادگان شامل ۱۴۱۴ واژه یکتا هستند که معادل آوایی آنها در دادگان موجود است.

فارسی دات بزرگ: این دادگان شامل حدود ۷۵۰ هزار واژه و دارای ۳۸۷۵۰ واژه یکتا است. متأسفانه برخلاف فارسی دات کوچک، فارسی دات بزرگ دارای واژگان و لغت نامه آوایی از لغات نیست. در واقع برچسب های واژه ای در این دادگان به صورت آوایی نوشته شده اند و معادل فارسی آنها موجود نیست. با وجود صرف وقت، تهیه لغت نامه از روی برچسب های آوایی و معادل سازی فارسی آنها کار زمان بری است؛ بنابراین در اینجا از همین برچسب های آوایی به عنوان واژگان بازشناسی گفتار استفاده شد. از جملاتی که متشکل از همین آواها بودند، مدل زبانی بازشناسی گفتار ساخته شد. پیکره آموزشی این مدل زبانی شامل حدود ۱۷۰۰ جمله و حدود پانصد هزار واژه که شامل متن های آموزش و توسعه است.

اخبار فارسی صداوسیما جمهوری اسلامی

ایران: در این حالت، از دو پیکره متنی برای ساخت مدل زبانی استفاده شد: پیکره همین دادگان و پیکره ایسنا. پیکره متنی ایسنا^۱ شامل حدود ۵۵۰ میلیون واژه و شامل اخبار خبرگزاری ایسنا است. پیکره دادگان اخبار فارسی از متن همین اخبار و شامل حدود ۳۰ هزار واژه است. علت انتخاب دو پیکره متنی برای ساخت مدل زبانی، تأثیر آن در رمزگشایی بازشناسی گفتار است؛ از آنجایی که اگر از متن مرتبط با دادگان گفتاری به عنوان پیکره متنی استفاده شود، مدل بیش برآزش^۲ می شود؛ از پیکره متنی جدا استفاده شد.

برای تهیه لغت نامه آوایی این دادگان، حدود شش هزار واژه یکتا به کار رفته در آن را استفاده کردیم. از آنجایی که لغت نامه آوایی واژه های این دادگان وجود نداشت، ساخت این لغت نامه به صورت دستی انجام و برای ساخت واژگان این دادگان، از واژگان زبانی فارسی [51] استفاده شد. واژگان زبانی زبان فارسی، شامل حدود ۵۵ هزار مدخل که هر مدخل دارای اطلاعات مربوط به صورت نوشتاری واژه در خط فارسی، ساخت واجی، مقوله واژگانی، الگوی تکیه و بسامد واژه است. برای تهیه واژگان زبانی، یک پیکره متنی ده میلیون واژه ای ملاک استخراج واژه ها قرار گرفته است. واژگان زبانی از حدود صد هزار واژه با بسامدهای متفاوت تشکیل شده است. بعد از حذف صورت های تصریفی از فهرست بالا، حدود ۴۴ هزار واژه به مفهوم علمی آن به دست آمد؛ همچنین برای غنی سازی فهرست مداخل به نحوی که شامل واژه های عامیانه و برخی واژه های علمی باشد، از فرهنگ فارسی امروز استفاده شده است. روند کار به این صورت بود که برخی از واژگان یکتای استفاده شده در دادگان اخبار فارسی در واژگان زبانی وجود داشت؛ دیگر واژه ها با استفاده از کتابخانه «هضم» [52] ریشه یابی^۳ شدند و اگر تلفظ ریشه ها و وندها در واژگان زبانی بودند به هم پیوند می خوردند تا تلفظ واژه پیدا شود. تلفظ برخی از واژه ها با هیچ کدام از این راه کارها ساخته نشد؛ بنابراین به صورت دستی تلفظ آنها نوشته شد.

در جدول (۳) خلاصه ای از اطلاعات متنی و واژگان دادگان آمده است.

برای آموزش مدل زبانی ابزار IRSTLM [53] به کار گرفته و از مدل زبانی سه تایی استفاده شد.

¹ ISNA

² Overfit

³ Stemmer

(جدول-۲): خلاصه اطلاعات دادگان. #spk تعداد گویندگان، T

مدت زمان به ساعت.

(Table-2): summary of databases. #spk Number of speakers, T length in hours.

دادگان	کل		آموزش		توسعه		آزمون	
	#s	#p	T	#sp	T	#sp	T	#sp
فارس دات کوچک	30	4	3	224	0.4	50	0.2	30
فارس دات بزرگ	10	0	71	73	11	16	8	11
اخبار فارسی صداوسیما	-	-	-	-	-	-	3	-

(جدول-۳): خلاصه اطلاعات پیکره متنی دادگان.

(Table-3): summary of text corpus of datasets

دادگان	تعداد واژه ها	تعداد واژه های یکتا
فارس دات کوچک	3 K	1.4k
فارس دات بزرگ	750 K	3.9 K
اخبار فارسی صداوسیما	30 K	6 K
ایسنا	550 M	990 K

۴-۳- سامانه تشخیص عبارتهای گفتاری

همان طور که در قبل گفته شد، یکی از چالش های استفاده از بازشناسی گفتار برای تشخیص عبارات، تشخیص کلیدواژه های خارج از واژگان است. این واژگان به هیچ وجه در خروجی بازشناسی نمایش داده نمی شوند و با روش های مبتنی بر تشخیص کلیدواژه های درون واژگان نمی توان آن ها را تشخیص داد. برای همین باید الگوریتم های متفاوتی برای تشخیص واژگان داخل واژگان و خارج از واژگان استفاده کرد. در واقع سامانه ارائه شده در این پژوهش، از دو الگوریتم جدا برای تشخیص این دو نوع کلیدواژه استفاده می کند.

برای کلیدواژه های خارج از واژگان از روش واژه های نماینده استفاده شد. یکی از مزیت های این روش، نیاز نبودن به نمایه کردن دوباره اسناد گفتار است و از نمایه مربوط به واژه های درون واژگان استفاده می کند که برای بهبود روش واژه های نماینده، از یک شبکه LSTM-CTC استفاده شد. آموزش این شبکه با ورودی های واژه به واژه به جای گفتار پیوسته است. برای آموزش، از دادگان فارس دات بزرگ با پانصد هزار واژه استفاده شده است. برای ارزیابی بهتر، شبکه LSTM مورد استفاده دارای یک تا پنج لایه دوسویه و ۱۵۰ سلول حافظه در هر لایه LSTM و دارای یک لایه پایانی

softmax است و در نهایت نتایج گزارش و با هم مقایسه شده اند.

۴-۴- معیارهای ارزیابی

۴-۴-۱- ارزیابی سامانه بازشناسی گفتار

در بازشناسی گفتار سه خطای حذف^۱، درج^۲ و جایگزینی^۳ اتفاق می افتد. خطای جایگزینی وقتی است که یک واژه به جای یک واژه دیگر بازشناسی شود. خطای حذف، بیان گر حالتی است که یک واژه که در گفتار وجود دارد، در خروجی بازشناسی حذف شود و خطای درج زمانی رخ می دهد که یک واژه که در گفتار وجود ندارد، در خروجی بازشناسی اضافه شود. برای ارزیابی بازشناسی گفتار از معیار نرخ خطای واژه (WER)^۴ استفاده شد که صورت این کسر بیان گر جمع این سه نوع خطا است:

$$WER = \frac{(N^{Del} + N^{ins} + N^{sub})}{N^{all}} \quad (۳)$$

۴-۴-۲- ارزیابی سامانه تشخیص عبارتهای گفتاری

دو معیار ارزیابی سامانه های تشخیص عبارتهای گفتاری در سال ۲۰۰۶ [3] معرفی شدند و هم اکنون نیز در معیارهای NIST استفاده می شوند [29]. معیار گرافیکی به وسیله منحنی های مصالحه تشخیص (DET)^۵ [54] و برای یک نقطه عملیاتی خاص در فضای منحنی DET از ارزش وزنی عبارت (TWV)^۶ استفاده می شود. اولی یک نمایش شهودی از عملکرد سامانه برای کاربردهای با دقت بالا یا فراخوانی بالا فراهم می کند. در حالی که TWV برای توسعه دهندگان یک معیار عملکرد واحد به عنوان هدفی برای بهینه سازی سامانه ایجاد می کند.

در تشخیص عبارتهای گفتاری، یک رخداد فرضی به عنوان تشخیص نامیده می شود؛ اگر تشخیص مربوط به رخداد درست باشد، یک موفقیت^۷ نامیده می شود، در غیر این صورت یک هشدار نادرست^۸ است. اگر رخداد درست تشخیص داده نشود، از دست رفته^۹ نامیده می شود. با توجه به

¹ Deletion

² Insertion

³ Substitution

⁴ Word Error Rate (WER)

⁵ Detection Error Tradeoff (DET) curves

⁶ Term-Weighted Value (TWV)

⁷ Hit

⁸ False alarm

⁹ Miss

اینکه این سامانه‌ها، سامانه‌های تشخیصی هستند، به حد آستانه تشخیص وابسته هستند. ارزش وزنی عبارت (TWV) برابر با یک منهای ارزش میانگین از دست داده‌شده سامانه در هر عبارت است؛ بنابراین به صورت زیر تعریف می‌شود:

$$TWV(\theta) = 1 - \text{average}_{term} \{P_{Miss}(term, \theta) + \beta \cdot P_{FA}(term, \theta)\} \quad (4)$$

$$\beta = \frac{C}{V} (Pr_{term}^{-1} - 1) \quad (5)$$

که در آن

$$P_{Miss}(term, \theta) = 1 - \frac{N_{correct}(term, \theta)}{N_{true}(term)} \quad (6)$$

$$P_{FA}(term, \theta) = \frac{N_{spurious}(term, \theta)}{N_{NT}(term)} \quad (7)$$

و $N_{correct}(term, \theta)$ تعداد درست (واقعی) تشخیص‌های term با یک امتیاز تشخیص مساوی یا بزرگ‌تر از θ ؛ $N_{spurious}(term, \theta)$ تعداد جعلی (غیرواقعی) تشخیص‌ها term با یک امتیاز تشخیص مساوی یا بزرگ‌تر از θ ؛ $N_{true}(term)$ تعداد واقعی وقوع term در دادگان؛ $N_{NT}(term)$ تعداد فرصت‌ها برای تشخیص غیرواقعی term در دادگان.

از آنجاکه هیچ ویژگی مجزا از «آزمایش‌ها» وجود ندارد؛ تعداد آزمایش‌های بدون هدف برای یک $N_{NT}(term)$ تا حدی قراردادی تعریف می‌شود تا با تعداد ثانیه‌های گفتار در دادگان آزمون متناسب باشد؛ به خصوص:

$$N_{NT}(term) = n_{tps} \cdot T_{speech} - N_{true}(term) \quad (8)$$

که n_{tps} تعداد آزمایش‌ها در ثانیه‌ی گفتار است (به صورت دلخواه برابر با یک تنظیم می‌شود). وزن β ، هم برای احتمال پیشین یک عبارت و هم برای وزن‌های نسبی برای هر نوع خطا در نظر گرفته می‌شود.

برای این ارزشیابی، نسبت هزینه/ارزش^۱، c/v برابر ۰/۱ است؛ بنابراین ارزش ازدست‌رفته در برابر یک هشدار نادرست ده برابر ارزش و احتمال پیشین یک term برابر 10^{-4} است.

بیشینه ممکن برای TWV برابر یک (۰/۱) متناظر با سامانه «تمام‌عیار» یعنی بدون هشدار نادرست و بدون miss

^۱ Cost/value ratio

است. سامانه‌ای که هیچ خروجی نداشته باشد TWV برابر صفر دارد و مقادیر منفی برای TWV هم ممکن هست. ارزش وزنی واقعی عبارت (ATWV)^۲: درحالی‌که منحنی‌های DET عملکرد را برای تمامی مقادیر ممکن θ نشان می‌دهند، دو نقطه از منحنی DET مورد توجه هستند؛ زیرا تعیین می‌کنند که آستانه تصمیم واقعی سامانه بهینه است یا نه. اولی، ارزش وزنی واقعی عبارت (ATWV) است که TWV با استفاده از تصمیم‌های واقعی محاسبه می‌شود. دومی، ارزش بیشینه وزنی عبارت (MTWV)^۳ هست. MTWV مقدار TWV در نقطه‌ای از منحنی DET است که یک مقدار از θ که TWV را بیشینه می‌کند. اختلاف بین مقادیر ATWV و MTWV نشان‌دهنده مزایای انتخاب آستانه تصمیم‌گیری واقعی بهتر است. معیار اصلی عملکرد سامانه تشخیص عبارات گفتاری، ATWV است که در اینجا از آن استفاده شده است.

۴-۵- نتایج سامانه بازشناسی گفتار

در این پژوهش از سامانه متن باز کلدی [48] به عنوان بستر بازشناسی گفتار استفاده شده است. دو سامانه بازشناسی گفتار به صورت جداگانه، یکی برای دادگان فارس‌دات کوچک و یکی برای دادگان فارس‌دات بزرگ آموزش داده و ارزیابی شد. برای دادگان اخبار فارسی از مدل آوایی فارس‌دات کوچک و بزرگ به صورت جداگانه استفاده شد. در رمزگشایی بازشناسی گفتار وزن مدل زبانی نقش دارد؛ از آنجایی که متن‌های آموزشی مدل زبانی محدود بودند و این بر روی نتایج مؤثر است، بهترین نتیجه‌ها با وزن مشخص‌شده مدل زبانی در بازه ۱ تا ۱۷ در جدول (۴) آمده است. برای ارزیابی بهتر مدل آوایی، نتایج با وزن یک، مدل زبانی در جدول (۵) آورده شده است. در این جدول‌ها مدل‌های آوایی HMM تک‌واج (mono)، سه‌واجی با ویژگی‌های دلتا و دلتا-دلتا (tri1)، سه‌واجی به همراه $LDA^4 + MLLT^5(tri2)$ ، سه‌واجی به همراه $LDA + MLLT + SAT^6(tri3)$ و $SGMM^7$ گزارش شده‌اند.

^۲ Actual Term Weighted Value (ATWV)

^۳ Maximum Term Weighted Value (MTWV)

^۴ Linear Discriminant Analysis

^۵ Maximum Likelihood Linear Transform

^۶ Speaker Adaptive Training

^۷ Subspace Gaussian Mixture Models

84/21	mono	فارس دات کوچک	اخبار فارسی
92/93	tri1		
99/47	tri2		
60/84	tri3		
49/8	SGMM		
68/71	mono	فارس دات بزرگ	
81/44	tri1		
76/39	tri2		
60/70	tri3		
35/37	SGMM		

به‌طورکلی آموزش مدل آوایی مخصوص یک گوینده نتایج بسیار بهتری نسبت به مدل آوایی مستقل از گویندگان دارد. آموزش مدل آوایی نیاز به تعداد بالای ساعت گفتاری دارد و جمع‌آوری این تعداد ساعت برای همه گوینده‌ها مقدور نیست؛ همچنین در برخی کاربردها از یک گوینده فقط مقدار کمی داده موجود است؛ بنابراین به مدل‌های آوایی مستقل از گوینده که بتوان با مقدار کمی داده با گوینده منطبق بشوند، نیاز است. از آنجایی که داده‌های آموزشی از گوینده‌های مختلف در دادگان کم هستند، آموزش مدل‌های آوایی به‌طورمعمول مستقل از گوینده آموزش داده می‌شوند و در مرحله آزمون روش‌های تطبیق گوینده مانند MLLT و SAT استفاده می‌شود [55]. ایده اصلی در MLLT استفاده از یک مبدل خطی هست؛ این مبدل خطی با بسیاری از گوسی‌ها مشترک هست و برای تغییر پارمترهای گوسی مدل آوایی از آن استفاده می‌شود. از آنجایی که این مبدل‌های خطی مشترک هستند، مقدار کمی از پارامترها نیاز به تخمین هستند.

در روش آموزشی بر پایه HMM در حالت‌های HMM، GMM‌ها به‌صورت مستقل در نظر گرفته می‌شود؛ در روش SGMM گوسی مشترک بین حالت‌ها در نظر گرفته می‌شود [56]. در روش SGMM یک مدل مخلوط جهانی بر مبنای کل گفتار آموزش داده می‌شود؛ سپس با تطبیق آن به مدل‌های مربوط به هر حالت می‌رسیم. آموزش با حجم داده‌های کم یکی از مزیت‌های این روش است.

با توجه به محدودبودن حجم دادگان در دسترس، در این پژوهش بر روی روش‌های یادگیری عمیق و شبکه‌های عصبی تمرکز نشد و از HMM استفاده شده است.

با توجه به نتایج، علت خطای کم در دادگان فارس‌دات بزرگ، استفاده از مدل زبانی فقط بر مبنای دادگان آن‌ها و همچنین شباهت و همگنی دادگان آزمون و آموزش این دو دادگان است. علت خطای بالا روی دادگان اخبار فارسی، درهم‌بودن آن‌ها و تفاوت با دادگان آموزش

(جدول-۴): بهترین نتایج خطای بازشناسی گفتار بر مبنای معیار WER با مدل زبانی منطبق با دادگان و وزن آن. HMM تک‌واج (mono)، سه‌واجی با ویژگی‌های دلتا و دلتا-دلتا (tri1)، سه‌واجی به همراه LDA + MLLT(tri2)، سه‌واجی به همراه LDA + MLLT + SAT(tri3) و SGMM.

(Table-4): Best results of speech recognition based on WER using language model matched to text of databases. Monophone(mono), triphone with delta and delta-delta (tri1), triphone with LDA+MLLT(ti2), triphone with LDA + MLLT + SAT(tri3), SGMM.

دادگان آزمون	مدل آوایی	وزن مدل زبانی	بهترین WER
فارس‌دات کوچک	mono	16	7/93
	tri1	17	9/72
	tri2	17	11/83
	tri3	17	11/35
	SGMM	17	9/55
فارس‌دات بزرگ	mono	11	9/46
	tri1	17	4/41
	tri2	17	4/7
	tri3	17	3/42
	SGMM	15	2/71
اخبار فارسی	فارس‌دات کوچک	mono	77/12
		tri1	77/23
		tri2	76/48
		tri3	51/52
		SGMM	34/40
	فارس‌دات بزرگ	mono	54/79
		tri1	79/69
		tri2	71/77
		tri3	59/29
		SGMM	28/23

(جدول-۵): نتایج خطای بازشناسی گفتار بر مبنای معیار WER با مدل زبانی منطبق بر دادگان و وزن یک. HMM تک‌واج (mono)، سه‌واجی با ویژگی‌های دلتا و دلتا-دلتا (tri1)، سه‌واجی به همراه LDA + MLLT(tri2)، سه‌واجی به همراه LDA + MLLT + SAT(tri3) و SGMM.

(Table-5): Results of speech recognition based on WER using language model matched to text of databases and language model weight equal one. Monophone(mono), triphone with delta and delta-delta (tri1), triphone with LDA+MLLT(ti2), triphone with LDA + MLLT + SAT(tri3), SGMM.

دادگان آزمون	مدل آوایی	WER
فارس‌دات کوچک	mono	16/7
	tri1	19/38
	tri2	22/4
	tri3	15/69
	SGMM	13/95
فارس‌دات بزرگ	mono	17/61
	tri1	11/49
	tri2	10/94
	tri3	8/50
	SGMM	6/53

است. دادگان آموزش فقط خوانش متون معیار فارسی است ولی دادگان اخبار فارسی مخلوطی از خوانش اخبار فارسی، گزارش‌ها در محیط‌های مختلف و گفتار همراه با موسیقی است.

برای ارزیابی بهتر سامانه بازشناسی اخبار فارسی از پیکره متنی ایسنا شامل ۵۵۰ میلیون واژه برای ساخت مدل زبانی استفاده و نتایج در جدول (۶) نمایش داده شده است. با مقایسه نتایج بازشناسی اخبار فارسی با مدل‌های زبانی منطبق بر خود دادگان (جدول ۴) و مدل زبانی وسیع‌تر (جدول ۶) می‌توان تأثیر مدل زبانی را بهتر مشاهده کرد. همان‌طور که انتظار می‌رفت نتایج برای مدل زبانی منطبق بر دادگان بهتر است.

(جدول ۶): نتایج خطای بازشناسی گفتار دادگان اخبار فارسی بر مبنای معیار WER با مدل زبانی بزرگ‌تر از متن دادگان.

(Table-6): Results of speech recognition based on WER for Persian IRIB News with larger language model than text of database.

دادگان	مدل زبانی	مدل آوایی	وزن مدل زبانی	WER
اخبار فارسی	ایسنا	mono	11	78/80
		tri1	12	83/25
		tri2	10	81/32
		tri3	15	60/22
		SGMM	9	43/74

۴-۶- نتایج سامانه تشخیص عبارت‌های گفتاری

همان‌طور که بحث شد، سامانه‌های تشخیص عبارت‌های گفتاری بر پایه بازشناسی گفتار داخل واژگان (INV) را می‌توانند تشخیص دهند و از آن‌جهت که واژه‌های خارج از واژگان (OOV) در خروجی بازشناسی گفتار هیچ اطلاعاتی از آن‌ها نیست، باید از روش‌های دیگر آن‌ها را تشخیص داد. در زیرتشخیص عبارت گفتاری از دو جهت INV و OOV ارزیابی شده است.

سامانه تشخیص واژگان داخل واژگان از روی الگوریتم معرفی شده در [5] ساخته شد. این الگوریتم در کلدی [48] پایریزی شده است و با استفاده از آن، این سامانه طراحی شد.

۴-۶-۱- کلیدواژه‌های درون واژگان سامانه بازشناسی گفتار (INV)

یکی از نکات در ارزیابی سامانه تشخیص عبارت‌های گفتاری، کلیدواژه‌های مورد جستجو در این سامانه‌ها است. از آنجایی که کلیدواژه‌های معیاری برای زبان فارسی وجود ندارد، تمامی واژه‌های یکتای پنج‌واژی دادگان به‌عنوان

کلیدواژه انتخاب شد. نکته‌ای دیگر حجم دادگان مورد آزمون است. معیار ارزیابی، ATWV، متناسب با حجم و طول دادگان آزمون است. ATWV بیانگر مجموع تمامی کلیدواژه‌ها و عبارت‌ها می‌باشد؛ بنابراین در دادگان آزمون با حجم کم اگر در تشخیص یک کلیدواژه با تعداد تکرار کم اشتباه شود، تأثیر به‌سزایی در کارایی دارد. این نکته در دادگان فارسی‌دات کوچک و اخبار اتفاق افتاده است. تعداد کلیدواژه‌ها برای دادگان فارسی‌دات کوچک ۱۶۸ کلیدواژه، فارسی‌دات بزرگ ۱۰۲۵۸ و اخبار فارسی ۳۵۹۱ در نظر گرفته شد. در جدول (۷) نتایج تشخیص عبارت‌های گفتاری بر اساس سامانه بازشناسی گفتار طراحی شده در جدول (۴) و معیار ATWV آمده است. در این نتایج برای بازشناسی دادگان اخبار فارسی فقط از مدل فارسی‌دات بزرگ استفاده شده است.

همان‌طور که در قسمت چالش‌ها گفته شد، خطای بازشناسی گفتار بر روی تشخیص عبارت‌ها تأثیر زیادی دارد. با مقایسه جدول نتایج بازشناسی گفتار (جدول ۴) و جدول نتایج سامانه تشخیص (جدول ۷) می‌توان دید که با کاهش خطای بازشناسی، نتایج بهتری برای تشخیص عبارت‌ها کسب شده است. همچنین از روی نتایج گزارش شده قبلی [2] می‌توان گفت با خطای بازشناسی در حد بیست تا سی درصد، می‌توان به نتایج بالا و قابل قبولی در بخش تشخیص رسید که این هم از روی جدول‌ها به‌وضوح قابل مشاهده است.

(جدول ۷): نتایج تشخیص عبارت‌ها با معیار ATWV و MTWV برای کلیدواژه‌های INV. از سامانه‌های بازشناسی آموزش داده شده در جدول (۴) برای ساخت سامانه تشخیص استفاده شده است. (در دادگان اخبار فارسی از مدل آوایی فارسی‌دات بزرگ استفاده شده و از مدل آوایی فارسی‌دات کوچک به‌علت خطای بالا صرف نظر شده است).


(Table-7): Results of STD based on ATWV & MTWV for INV keywords. ASR in Table 4 used for STD. (In Persian news dataset we used only acoustic model based large FarsDat and regardless of small FarsDat since WER is too big).

دادگان	مدل آوایی	ATWV	MTWV
فارسی‌دات کوچک	mono	0/8353	0/8456
	tri1	0/7814	0/7886
	tri2	0/7297	0/7731
	tri3	0/7638	0/7925
	SGMM	0/8367	0/8418
فارسی‌دات بزرگ	mono	0/8944	0/8949
	tri1	0/9063	0/9064
	tri2	0/9076	0/9078
	tri3	0/9098	0/9104
	SGMM	0/9204	0/9206
اخبار فارسی	mono	0/4378	0/4597
	tri2	0/2387	0/2651
	tri3	0/5628	0/5795
	SGMM	0/7933	0/8008

واژه‌های نماینده و مرحله بعد خروجی‌های واژه‌های نماینده به یک سامانه بازشناسی LSTM-CTC داده می‌شود، تا دوباره امتیازبندی و ارزیابی شوند. همان‌طور که اشاره شد، شبکه LSTM-CTC به‌صورت واژه به واژه و نه بر اساس گفتار پیوسته آموزش داده شده است و تنها خروجی‌های نماینده را بر اساس واژه‌های جداگانه بازشناسی می‌کند و امتیاز اطمینان دوباره تخمین زده می‌شود.

در روش واژه‌های نماینده تعداد واژه‌های مشابه آوایی کلیدواژه مهم هستند و با افزایش تعداد واژه‌های نماینده به‌ازای کلیدواژه به‌طور معمول ΔTWV روند افزایشی و سپس کاهشی دارد [31]؛ این به خاطر افزایش هشدارهای نادرست است؛ هرچند که تعداد ازدست‌رفته‌ها کاهش می‌یابد. از آنجایی که خطای هشدار نادرست در ΔTWV دارای جریمه‌ده‌برابری نسبت به خطای ازدست‌رفته است، افزایش هشدارهای نادرست تأثیر بدتری بر روی ΔTWV می‌گذارد. تعداد نماینده‌ها به‌ازای هر کلیدواژه به تعداد واژه‌های واژگان بازشناسی گفتار وابسته است. در اینجا به‌علت محدودبودن تعداد واژه‌ها در واژگان (حدود ۳۸ هزار واژه) به نظر می‌رسد؛ تعداد نماینده‌ها به‌ازای هر کلیدواژه تأثیری بر ΔTWV نمی‌گذارد.

در شکل (۴) نتایج روش واژه‌های نماینده و روش بهبود آن، روش تصدیق LSTM-CTC بر مبنای معیار ΔTWV آمده است. با مقایسه نتایج، بهبود تا پنجاه درصد در این روش به‌دست آمده است. همان‌طور که در شکل‌های (۵ و ۶) مشاهده می‌شود، شبکه LSTM-CTC درصد خطای از دست‌رفته را کاهش می‌دهد ولی هم‌زمان خطای هشدار نادرست را افزایش می‌دهد ولی در مجموع معیار ΔTWV روند افزایشی نسبت به روش واژه‌های نماینده دارد، ولی نسبت به خود روش LSTM-CTC روند نزولی است.



(شکل-۴): نتایج حاصل از روش واژه‌های نماینده و روش بهبود آن، روش تصدیق LSTM-CTC بر مبنای معیار ΔTWV .
(Figure-4): Results of proxy words and improve it based on LSTM-CTC validation.

در جدول (۸) زمان اجرای نمایه‌گذاری و جستجو بر روی داده‌های فارسی‌دات بزرگ گزارش شده که بر روی سیستمی با مشخصات زیر اجرا شده است:

Intel(R) Core(TM) i7-6500U CPU @ 2.50GHz, 2592 Mhz, 2 Cores, 4 Logical Processors

(جدول-۸): زمان اجرای نمایه‌گذاری و جستجو بر روی داده‌های فارسی‌دات بزرگ

(Table-8): Time of indexing and searching for large FarsDat dataset

پردازش	زمان (ثانیه)
نمایه‌گذاری	141
جستجو	77

۲-۶-۴- کلیدواژه‌های خارج از واژگان سامانه بازشناسی گفتار (OOV)

همان‌طور که در بخش قبل اشاره شد، حجم دادگان و تعداد کلیدواژه‌ها در معیار ارزیابی ΔTWV تأثیر به‌سزایی دارد و در دادگان آزمون با مدت زمان کم اگر در تشخیص یک کلیدواژه با تعداد تکرار کم، اشتباهی رخ دهد، تأثیر به‌سزایی در ΔTWV دارد. از آنجایی که حجم دادگان فارسی‌دات کوچک کم است، ارزیابی کلیدواژه‌های OOV فقط بر روی دادگان فارسی‌دات بزرگ انجام گرفت.

به‌علت اینکه تمامی واژه‌های دادگان درون واژگان سامانه‌های بازشناسی گفتار طراحی شده بودند، تعداد ۵۱۵ کلیدواژه بین چهار واج تا هشت واج از واژگان بازشناسی حذف شد و عمل بازشناسی دوباره بر روی دادگان فارسی‌دات بزرگ آموزش داده شد و مورد آزمون قرار گرفت. خطای WER این حالت از بازشناسی گفتار در جدول (۹) آمده است.

(جدول-۹): نتایج مدل‌های بازشناسی گفتار آموزش داده‌شده با حذف ۵۱۵ واژه از واژگان؛ برای بررسی روش‌های تشخیص


کلیدواژه‌های OOV

(Table-9): Results of ASR with delete 515 words from the ASR lexicon, since evaluating STD for OOV keywords.


دادگان	مدل آوایی	وزن مدل زبانی	بهترین WER
فارسی‌دات بزرگ	mono	7	56/8456
	tri1	9	37/7886
	tri2	10	36/7731
	tri3	12	36/7925
	SGMM	9	28/8418

سامانه تشخیص عبارت بر روی OOV بر پایه مشبک خروجی مدل آموزشی SGMM برای بازشناسی و در دو مرحله طراحی شد. یک مرحله پایه‌ای بر اساس الگوریتم

در اینجا دوباره انتخاب کلیدواژه‌ها اهمیت پیدا می‌کنند، درواقع کلیدواژه‌های انتخابی برای کلیدواژه‌های OOV با واژه‌های داخل واژگان شباهت بالایی دارند. به‌طور مثال واژه «زیاد» به‌عنوان واژه خارج از واژگان انتخاب شده است ولی واژه‌های «زیاد» و «زیادی» در واژگان بازشناسی گفتار هستند که این می‌تواند عامل بالارفتن هشدارهای نادرست باشد. درنهایت با ارزیابی نتایج بر روی کلیدواژه‌های INV و OOV مقدار 0.7871 برای معیار ATWV حاصل شد.



(شکل-۵): درصد خطای از دست‌رفته حاصل از روش واژه‌های نماینده و روش بهبود آن، روش تصدیق LSTM-CTC.
(Figure-5): PMiss for proxy words and improve it based on LSTM-CTC validation.



(شکل-۶): درصد خطای هشدار نادرست حاصل از روش واژه‌های نماینده و روش بهبود آن، روش تصدیق LSTM-CTC.
(Figure-6): PFA for proxy words and improve it based on LSTM-CTC validation.

۷-۴- مقایسه با روش‌های پیشین فارسی

خلاصه‌ای از نتایج روش‌های مورد استفاده در زبان فارسی و دیگر زبان‌ها در جدول (۱) آمده است. در زبان انگلیسی به‌دلیل وجود دادگان عظیم و متنوع چالش بازشناسی گفتار و به‌کارگیری آن در تشخیص عبارت‌های گفتاری دست‌کم در اخبار رسمی حل شده عنوان شده است [5]. در حال

حاضر پژوهش‌ها بر روی زبان‌هایی با داده‌های کم متمرکز شده‌اند [29]. در اینجا به‌دلیل وجود دادگان مختلف و حجم متفاوت آن‌ها نمی‌توان به معیار مشخصی برای مقایسه روش‌ها رسید.

در [4]، ده روش بر روی زبان اسپانیایی به‌کار گرفته شده است. همان‌طور که در مقاله عنوان شده است، دادگان EPIC دادگان معیار و با لهجه‌ی اسپانیایی و MAVIR دادگان با تنوع دادگان بیشتری هستند و طبق معیار ATWV به‌ترتیب به اعداد 0.93 و 0.64 برای تشخیص عبارت‌های گفتاری رسیده‌اند. کاهش معیار بر روی این دادگان به‌دلیل تفاوت آن‌ها محسوس است.

در مقاله‌های [6]، [8] روش استفاده از بازشناسی گفتار بر زبان‌های با دادگان محدود بررسی شده است. برای مقایسه روش‌های فارسی، به‌دلیل تفاوت دادگان و کلیدواژه‌ها نمی‌توان بررسی دقیقی انجام داد.

در [37] همانند این مقاله از دادگان فارسی‌دات بزرگ استفاده شده و از روش مبدل عامل برای نمایه‌گذاری استفاده کرده و همچنین از دو نمایه‌گذاری واژه‌ای و واجی به‌صورت موازی استفاده کرده است. این پایان‌نامه به نرخ خطای واژه و ATWV مشابه این مقاله رسیده ولی روشی برای جستجوی کلیدواژه‌های OOV بررسی نکرده است. در [9] که به نظر تکمیل‌کننده پایان‌نامه قبلی است؛ تمرکز بر روی دادگان محدود و کلیدواژه‌های OOV شده است. در این پایان‌نامه از روش واژه‌های نماینده استفاده شده و با روش گسترش واژه‌ها این روش را تقویت کرده است. با توجه به نرخ بالای واژه‌های خارج از واژگان نتایج خوبی گرفته شده است. در [38] از روش جستجو تنها بر روی رشته واج نه واژه استفاده شده و از روش‌های مبدل عامل و فاصله‌یاب لونشتاین برای جستجو بهره گرفته است. در مقایسه با روش‌های دیگر در زبان‌های دیگر به نتایج عددی بسیار بزرگ‌تری رسیده است [4]^۱ (حدود چهار برابر) ولی نحوه انتخاب کلیدواژه‌ها، نوع داده‌ها در این اعداد مهم است. مقاله کنونی درواقع نوعی تکمیل‌کننده روش‌های [9]، [37] با مقیاس بزرگ‌تر و با دادگان واقعی‌تر است.

۵- نتیجه‌گیری

در این مقاله یک سامانه تشخیص عبارت‌های گفتاری برای اخبار فارسی و دادگان فارسی‌دات بزرگ ارائه شد. تشخیص

^۱ روش Phone STD در مقاله مذکور.

حجم پیکره متنی؛ به کارگیری از روشهای نرمالیزه کردن نمره‌های عبارتهای جستجو [58] برای نرمال کردن خروجی شبکه LSTM-CTC.

6- References

۶- مراجع

- [1] L. Lee, J. Glass, H. Lee, and C. Chan, "Spoken Content Retrieval—Beyond Cascading Speech Recognition with Text Retrieval," *IEEE/ACM Trans. Audio, Speech, Lang. Process.*, vol. 23, no. 9, pp. 1389–1420, Sep. 2015.
- [2] M. Larson and G. J. F. Jones, "Spoken Content Retrieval: A Survey of Techniques and Technologies," *Found. Trends® Inf. Retr.*, vol. 5, no. 3, pp. 235–422, 2012.
- [3] J. G. Fiscus, J. Ajot, J. S. Garofolo, and G. Doddington, "Results of the 2006 Spoken Term Detection Evaluation," *Proc. ACM SIGIR Work. Search. Spontaneous Conversational.*, pp. 51–55, 2006.
- [4] J. Tejedor et al., "ALBAYZIN 2016 spoken term detection evaluation: an international open competitive evaluation in Spanish," *EURASIP J. Audio, Speech, Music Process.*, vol. 2017, no. 1, p. 22, 2017.
- [5] J. S. Garofolo, C. G. P. Auzanne, and E. M. Voorhees, "The TREC Spoken Document Retrieval Track: A Success Story," *Proc. TREC-8*, vol. 8940, no. 500–246, pp. 109–130, 1999.
- [6] J. Trmal et al., "The Kaldi OpenKWS System: Improving Low Resource Keyword Search," *Interspeech2017*, pp. 3597–3601, 2017.
- [7] X. Angucra, L. J. Rodriguez-Fuentes, A. Buzo, F. Metze, I. Szoke, and M. Penagarikano, "QUESST2014: Evaluating Query-by-Example Speech Search in a zero-resource setting with real-life queries," *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2015-Augus, pp. 5833–5837, 2015.
- [8] T. Alumäe et al., "The 2016 BBN Georgian telephone speech keyword spotting system," *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, pp. 5755–5759, 2017.
- [9] Z. Gomar, "مدل‌های بیانی تمایزی برای تشخیص عبارات گفتاری در شرایط با منابع محدود," پایان‌نامه کارشناسی ارشد، صنعتی شریف، ۱۳۹۴.
- [9] Z. Gomar, Discriminative Articulatory Models for Spoken Term Detection in Low-Resource Conditions, M.S. Thesis, Sharif University of Technology, 2016.
- [10] M. Crochemore, "Transducers and repetitions," *Theor. Comput. Sci.*, vol. 45, pp. 63–86, 1986.

عبارتهای گفتاری یا جستجوی کلیدواژه‌ها روش‌هایی برای جستجوی دقیق یک عبارت و یا کلیدواژه درون یک سند گفتاری یا فایل صوتی ارائه می‌کنند. در این پژوهش از روشی بر پایه سامانه بازشناسی گفتار استفاده شد. در این روش ابتدا گفتار ورودی به مشبک بازشناسی می‌شود و سپس بر روی مشبک جستجو انجام می‌گیرد. یکی از چالش‌های این روش واژه‌های خارج از واژگان (OOV) است؛ این واژه‌ها در خروجی بازشناسی گفتار نمایش داده نمی‌شوند؛ بنابراین با روش‌های دیگری باید برای جستجوی آن‌ها را انجام داد. برای کلیدواژه‌های خارج از دادگان در این مقاله از روش واژه‌های نماینده کمک گرفته شد. در این روش به جای جستجوی مستقیم کلیدواژه، واژه‌هایی که از نظر آوایی شباهت به آن‌ها دارند و در بین واژگان ASR هستند، مورد جستجو قرار می‌گیرند.

در این پژوهش برای بازشناسی گفتار از مدل‌های مخفی مارکوف استفاده و از دادگان فارسی‌دات بزرگ برای آموزش مدل آوایی استفاده شد. ارزیابی این مدل بر روی دادگان فارسی‌دات بزرگ با روش آموزشی SGMM خطای ۲۸/۲۳ و بر روی دادگان اخبار فارسی خطای ۲۸/۲۳ حاصل شد. در تشخیص عبارتهای معیار ATWV با بازه بین منفی بی‌نهایت تا مثبت یک در نظر گرفته شد. تشخیص عبارتهای گفتاری در دو سطح کلیدواژه‌های داخل واژگان (INV) و خارج واژگان (OOV) به‌طور جداگانه انجام گرفت. در سطح کلیدواژه‌های INV بر روی دادگان فارسی‌دات بزرگ مقدار ۰/۹۲۰۶ و برای دادگان اخبار فارسی مقدار ۰/۸۰۰۸ نتیجه و در سطح کلیدواژه‌های OOV با استفاده از روش واژه‌های نماینده مقدار ۰/۲۰۰۲ برای دادگان فارسی‌دات بزرگ حاصل شد. برای بهبود عملکرد این سامانه از یک شبکه LSTM-CTC بر پایه‌ی آموزشی واژه استفاده شد که درنهایت با حدود پنجاه درصد افزایش مقدار ۰/۳۰۵۸ حاصل شد.

برای ادامه پژوهش می‌توان به موارد زیر اشاره کرد: مطالعه بر روی انواع مختلف مدل کردن زیرواژه‌ها در زبان فارسی برای جستجوی کلیدواژه‌های خارج از دادگان؛ همانند [57] در زبان اسپانیایی و دیگر زبان‌ها [2]؛ استفاده از روش‌های بازیابی و روش‌هایی که در آن به‌صورت یکجا سامانه را نظر می‌گیرند [1]؛ استفاده از روش‌های آموزشی شبکه‌های عصبی برای مدل آوایی متناسب با مدت‌زمان دادگان؛ به‌کارگیری از مدل‌های زبانی با تعداد واژه‌های بیش‌تر و روش‌های آموزشی شبکه‌های عصبی متناسب با

spoken term detection using attention-based multi-hop networks,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2018-April, pp. 6264–6268, 2018.

- [24] R. C. Rose and D. B. Paul, “A hidden Markov model based keyword recognition system,” *Int. Conf. Acoust. Speech, Signal Process.*, pp. 129–132 vol.1, 1990.
- [25] J. G. Wilpon, L. R. Rabiner, C.-H. Lee, and E. R. Goldman, “Automatic Recognition of Keywords in Unconstrained Speech Using Hidden Markov Models,” *Ieee Tasp*, vol. 3, no. 1, pp. 1870–1878, 1990.
- [26] A. Tavanaei, H. Sameti, and S. H. Mohammadi, “False alarm reduction by improved filler model and post-processing in speech keyword spotting,” *IEEE Int. Work. Mach. Learn. Signal Process.*, 2011.
- [27] R. Sukkar and J. Wilpon, “A two pass classifier for utterance rejection in Keyword Spotting,” *Acoust. Speech, Signal ...*, pp. 1–4, 1993.
- [28] M. G. Rahim, C. H. Lee, and B. H. Juang, “Discriminative utterance verification for connected digits recognition,” *IEEE Trans. Speech Audio Process.*, vol. 5, no. 3, pp. 266–277, 1997.
- [29] “KWS16 Evaluation Plan.” [Online]. Available: <https://www.nist.gov/%0Asites/default/files/documents/itl/iad/mig/KWS16-evalplan-v04.pdf>.
- [30] C. Chelba, J. Silva, and A. Accro, “Soft indexing of speech content for search in spoken documents,” *Comput. Speech Lang.*, vol. 21, no. 3, pp. 458–478, Jul. 2007.
- [31] G. Chen, O. Yilmaz, J. Trmal, D. Povey, and S. Khudanpur, “Using proxies for OOV keywords in the keyword search task,” in *2013 IEEE Workshop on Automatic Speech Recognition and Understanding*, 2013, pp. 416–421.
- [32] T. K. Chia, K. C. Sim, H. Li, and H. T. Ng, “Statistical lattice-based spoken document retrieval,” *ACM Trans. Inf. Syst.*, vol. 28, no. 1, pp. 1–30, Jan. 2010.
- [33] Y. C. Pan and L. S. Lee, “Performance analysis for lattice-based speech indexing approaches using words and subword units,” *IEEE Trans. Audio, Speech Lang. Process.*, vol. 18, no. 6, pp. 1562–1574, 2010.
- [34] W. Hartmann, V. B. Le, A. Messaoudi, L. Lamel, and J. L. Gauvain, “Comparing decoding strategies for subword-based keyword spotting in low-resourced languages,” *Proc. Annu. Conf. Int. Speech Commun. Assoc. INTERSPEECH*, no. September, pp. 2764–2768, 2014.
- [35] L. S. Lee and Y. C. Pan, “Voice-based information retrieval - How far are we from the text-based information retrieval?,” *Proc. 2009*
- [11] J. S. Bridle, “An efficient elastic-template method for detecting given words in running speech,” *Brit. Acoust. Soc. Meet.*, pp. 1–4, 1973.
- [12] A. Mandal, K. R. Prasanna Kumar, and P. Mitra, “Recent developments in spoken term detection: a survey,” *Int. J. Speech Technol.*, vol. 17, no. 2, pp. 183–198, Jun. 2014.
- [13] J. Bridle, “An efficient elastic template method for detecting given keywords in the running speech,” *Proc. Br. Acoust. Soc. Meet.*, pp. 1–4, 1973.
- [14] C. Parada, A. Sethy, and B. Ramabhadran, “Query-by-example spoken term detection for OOV terms,” *Proc. 2009 IEEE Work. Autom. Speech Recognit. Understanding, ASRU 2009*, pp. 404–409, 2009.
- [15] J. Tejedor, I. Szöke, and M. Fapso, “Novel methods for query selection and query combination in query-by-example spoken term detection,” *Proc. 2010 Int. Work. Search. spontaneous conversational speech - SSCS '10*, pp. 15–20, 2010.
- [16] M. C. Madhavi and H. A. Patil, “Partial matching and search space reduction for QbE-STD,” *Comput. Speech Lang.*, vol. 45, pp. 58–82, Sep. 2017.
- [17] Y. Zhang and J. R. Glass, “Unsupervised spoken keyword spotting via segmental DTW on Gaussian posteriorgrams,” *Proc. 2009 IEEE Work. Autom. Speech Recognit. Understanding, ASRU 2009*, pp. 398–403, 2009.
- [18] M. Huijbregts, M. McLaren, and D. Van Leeuwen, “Unsupervised acoustic sub-word unit detection for query-by-example spoken term detection,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, pp. 4436–4439, 2011.
- [19] P. Fousek and H. Hermansky, “Towards ASR Based on Hierarchical Posterior-Based Keyword Recognition,” *2006 IEEE Int. Conf. Acoust. Speed Signal Process. Proc.*, vol. 1, pp. I-433–I-436.
- [20] H. Sakoe and S. Shiba, “Dynamic programming algorithm optimization for spoken word recognition,” *IEEE Trans. Acoust. Speech Signal Process.*, vol. 26, no. 1, pp. 43–49, 1978.
- [21] C. Chan and L. Lee, “Unsupervised Spoken-Term Detection with Spoken Queries Using Segment-based Dynamic Time Warping,” *Evaluation*, no. September, pp. 693–696, 2010.
- [22] D. Ram, L. Miculicich, and H. Bourlard, “CNN based query by example spoken term detection,” *Proc. Annu. Conf. Int. Speech Commun. Assoc. INTERSPEECH*, vol. 2018-September, pp. 92–96, 2018.
- [23] C. W. Ao and H. Y. Lee, “Query-by-example

- [42] H. Naderi, Keyword Spotting in Speech Utterance, M.S. thesis, Shahrood University of Technology, 2013.
- [43] M. Bijankhan, J. Sheikhzadegan, M. R. Roohani, Y. Samareh, C. Lucas, and M. Tebyani, "FARSDAT-The speech database of Farsi spoken language," *Proc. Aust. Conf. Speech Sci. Technol.*, vol. 2, no. 0, pp. 826-831, 1994.
- [44] J. Sheikhzadegan and M. Bijankhan, "Persian speech databases," *2nd Work. Persian Lang. Comput.*, pp. 247-261, 2006.
- [45] M. Bijankhan, J. Sheikhzadegan, M. R. Roohani, R. Zarrintare, S. Z. Ghasemi, and M. E. Ghasedi, "Tfarsdat - The telephone farsi speech database," *EUROSPEECH 2003 - 8th Eur. Conf. Speech Commun. Technol.*, 2003.
- [46] D. Can and M. Saraclar, "Lattice Indexing for Spoken Term Detection," *IEEE Trans. Audio. Speech. Lang. Processing*, vol. 19, no. 8, pp. 2338-2347, Nov. 2011.
- [47] Z. Lv, J. Kang, W. Q. Zhang, and J. Liu, "An LSTM-CTC based verification system for proxy-word based OOV keyword search," *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, pp. 5655-5659, 2017.
- [48] C. Parada, A. Sethy, and B. Ramabhadran, "Balancing false alarms and hits in spoken term detection," *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, pp. 5286-5289, 2010.
- [49] Z. Victor, S. Seneff, and J. Glass, "TIMIT acoustic-phonetic continuous speech corpus," *Speech Commun.*, vol. 9, no. 4, pp. 351-56, 1990.
- [50] ب. باباعلی، "پایه گذاری بستری نو و کارآمد در حوزه بازشناسی گفتار فارسی،" *پروازش علایم و داده ها*، شماره ۱۳ (۳)، صص ۵۱-۵۲، ۱۳۹۵.
- [50] B. BabaAli, "State-of-the-art and Efficient Framework for Persian Speech Recognition," *jsdp*, Vol (3), pp. 51-62, 2017.
- [51] م. اسلامی، م. شریفی آتشگاه، ص. علیزاده لمجیری ط. زندی، "واژگان زایای زبان فارسی،" *مجموعه مقالات اولین کارگاه پژوهشی زبان فارسی و رایانه*، ۱۳۸۳.
- [51] M. Eslami, M. Sharifi Atashgah, S. Alizade, T. Zandi, "Persian Generative Lexicon" *Proceedings of the first Persian language and computer research workshop*, 2005.
- [52] "Hazm. هضم،" [Online]. Available: <https://github.com/sobhc/hazm>.
- IEEE Work. Autom. Speech Recognit. Understanding, ASRU 2009*, pp. 26-43, 2009.
- [36] D. Can, "Indexation, retrieval & decision techniques for spoken term detection," PhD diss, Boğaziçi University, 2010.
- [۳۷] م. غدیری نیا، "طراحی و بهبود یک سامانه‌ی تشخیص اصطلاحات گفتاری،" پایان‌نامه کارشناسی ارشد، صنعتی شریف، ۱۳۹۳.
- [37] M. Qadiri Nia, "Design and Performance Improvement of a Spoken Term Detection System", M.S. thesis, Sharif University of Technology, 2015.
- [۳۸] م. عباسیان، "شناسایی کلمات کلیدی در گفتار فارسی توسط سیستم تلفیقی مدل مخفی مارکوف و شبکه‌های عصبی عمیق،" پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی امیرکبیر، ۱۳۹۵.
- [38] M. Abbassian, "Keyword Spotting in Persian Speech Using a Hybrid Model of DNN and HMM", M.S. thesis, Amir Kabir University of Technology, 2017.
- [۳۹] س. س. صرفجو، "چارچوبی جدید برای بازیابی اطلاعات به منظور استفاده در بازیابی صدای گفتاری فارسی،" پایان‌نامه کارشناسی ارشد، دانشگاه قم، ۱۳۹۰.
- [39] S.S. Sarfjou, "Introducing a New Information Retrieval Framework for Persian Speech Retrieval, M.S. thesis, Qom University, 2012.
- [۴۰] م. ی. اخلاقی، "ارائه یک روش جدید بازیابی اطلاعات مناسب برای متون حاصل از بازشناسی گفتار،" پایان‌نامه کارشناسی ارشد، دانشگاه قم، ۱۳۹۲.
- [40] M.Y. Akhlaqi, "Introducing a New Information Retrieval Method for Speech Recognized Texts, M.S. thesis, Qom University, 2014.
- [۴۱] م. ح. سلطانی، "چارچوبی جدید برای بازشناسی گفتار به منظور استفاده در بازیابی صدای گفتاری،" پایان‌نامه کارشناسی ارشد، دانشگاه قم، ۱۳۹۲.
- [41] M.H. Soltani, "Introducing a New Information Retrieval Framework for Speech Retrieval" M.s. thesis, Qom University, 2014.
- [۴۲] ه. نادری، "جستجوی کلمات کلیدی در رشته‌ی گفتار،" پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی شاهرود، ۱۳۹۱.
- [42] H. Naderi, "Keyword Spotting in Speech Utterance, M.S. thesis, Shahrood University of Technology, 2013.



اعظم باستان فرد، درجه دکترا را در رشته علوم رایانه از دانشگاه صنعتی توکیو و فوق دکترا را در سال ۱۳۸۴ در گرافیک رایانه‌ای از دانشگاه ژنو کسب کرده‌اند. ایشان هم‌اکنون به‌عنوان عضو هیأت علمی دانشگاه آزاد واحد کرج مشغول به تدریس دروس نرم‌افزار و پردازش داده است. زمینه‌های پژوهشی ایشان پردازش صدا و تصویر، یادگیری ماشین، گرافیک رایانه‌ای و بازی‌های رایانه‌ای است.

نشانی رایانامه ایشان عبارت است از:

bastanfard@kiaui.ac.ir

- [53] M. Federico, N. Bertoldi, and M. Cettolo, "IRSTLM: An open source toolkit for handling large scale language models," *Proc. Annu. Conf. Int. Speech Commun. Assoc. INTERSPEECH*, pp. 1618–1621, 2008.
- [54] A. Martin, G. Doddington, T. Kamm, M. Ordowski, and M. Przybocki, "The DET Curve in Assessment of Detection Task Performance," *Proc. Eurospeech '97*, pp. 1895–1898, 1997.
- [55] D. Jurafsky and J. H. Martin, *Speech and language processing*. 1999.
- [56] D. Povey *et al.*, "The subspace Gaussian mixture model - A structured model for speech recognition," *Comput. Speech Lang.*, vol. 25, no. 2, pp. 404–439, 2011.
- [57] J. Tejedor, D. Wang, J. Frankel, S. King, and J. Colás, "A comparison of grapheme and phoneme-based units for Spanish spoken term detection," *Speech Commun.*, vol. 50, no. 11–12, pp. 980–991, 2008.
- [58] Y. Wang and F. Metze, "An in-depth comparison of keyword specific thresholding and sum-to-one score normalization," *Proc. Annu. Conf. Int. Speech Commun. Assoc. INTERSPEECH*, pp. 2474–2478, 2014.



هادی ویسی مدرک دکترای خود را در رشته مهندسی رایانه در سال ۱۳۹۰ از دانشگاه صنعتی شریف دریافت کرده و از سال ۱۳۹۱ عضو هیأت علمی دانشگاه تهران است. زمینه‌های تخصصی ایشان پردازش زبان طبیعی و پردازش گفتار، یادگیری ماشین، شبکه‌های عصبی مصنوعی و یادگیری عمیق است.

نشانی رایانه ایشان عبارت است از:

h.veisi@ut.ac.ir



سید اکبر قریشی مدرک کارشناسی خود را در سال ۱۳۹۳ در رشته مهندسی برق (گرایش مخابرات) از دانشگاه یزد دریافت کرد. ایشان در سال ۱۳۹۸ از دانشگاه صدا و سیما در مقطع کارشناسی ارشد در رشته مهندسی صدا فارغ‌التحصیل شد. وی از سال ۱۳۹۷ عضو آزمایشگاه پردازش علائم و داده‌های دانشگاه تهران است. زمینه مورد علاقه وی پردازش گفتار و بازشناسی گفتار است.

نشانی رایانامه ایشان عبارت است از:

akbar20gh@gmail.com