



ارائه یک روش جدید بازیابی اطلاعات مناسب برای متون حاصل از بازشناسی گفتار

روح الله دیانت^۱، مرتضی علی احمدی^۲، محمد یحیی اخلاقی^۳ و باقر باباعلی^۴

^{۱،۲} گروه مهندسی فناوری اطلاعات، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران

^۳ گروه علوم کامپیوتر، دانشگاه خاتم النبیین، کابل، افغانستان

^۴ پردیس علوم، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشگاه تهران، تهران، ایران



چکیده

در این مقاله، یک پیش پردازش روی روش های بازیابی اطلاعات، ارائه می شود که برای بازیابی اطلاعات حاصل از متون بازشناسی شده گفتاری، مناسب است. این پیش پردازش، به شکل ترکیبی از اصلاح و گسترش پرس وجو است. ورودی های مسئله، اسناد متنی به دست آمده از بازشناسی گفتار و پرس وجو است و هدف، یافتن اسناد مرتبط با کلمه پرس وجو است. مشکل آن است که متن حاصل از بازشناسی گفتار، همواره دارای درصد خطایی در بازشناسی است که ممکن است منجر به این شود که کلماتی که در واقع مرتبط هستند و به علت وقوع خطای بازشناسی دگرگون شده اند، مرتبط تشخیص داده نشوند.

ایده روش ارائه شده، تشخیص خطای بازشناسی در کلمات و در نظر گرفتن کلمات مشابه برای آن دسته از کلماتی است که به عنوان خطا تشخیص داده شده اند. برای تشخیص کلمه خطا، پارامتری به عنوان احتمال خطا در کلمه تعریف می شود که بزرگ بودن آن بیان گر امکان بیشتر وقوع خطا در کلمه است. همچنین برای تشخیص کلمات مشابه، ابتدا با استفاده از معیار فاصله لونشتاین، کلمات مشابه اولیه را پیدا می کنیم؛ سپس احتمال تبدیل این کلمات مشابه به کلمه پرس وجوی اصلی، محاسبه می شود. کلمات مشابه معنایی، از بین کلماتی که احتمال تبدیل بیش تری دارند، بر اساس یک سطح آستانه انتخاب می شوند. اکنون در الگوریتم بازیابی، علاوه بر کلمه اصلی، کلمات مشابه آن نیز در جستجو، مرتبط در نظر گرفته می شوند. نتایج پیاده سازی ها نشان می دهد که الگوریتم ارائه شده، معیار F را به میزان حداکثر ۳۰٪ بهبود می بخشد.

واژگان کلیدی: بازیابی اطلاعات، بازشناسی گفتار، سند، پرس وجو، فاصله لونشتاین

Introducing a New information Retrieval Method Applicable for Speech Recognized Texts

Rouhollah Dianat¹, MortezaAli Ahmadi², MohammadYahya Akhlaghi³ & Bagher Babaali⁴

^{1,2} Department of Information Technology Engineering, Faculty of Technical and Engineering, University of Qom, Qom, Iran

³ Lecturer in Department of Computer Science, University of Khatam Al Nabeyin, Kabol, Afghanistan

⁴ College of Science, Faculty of Mathematics, Statistics and Computer Science, University of Tehran, Tehran, Iran

Abstract

In this article a pre-processing method is introduced which is applicable in speech recognized texts retrieval task. We have a text corpus, generated from a speech recognition system and a query as inputs, to search queries in these documents and find relevant documents. A basic problem in a typical speech recognized text

is some error percentage in recognition. This, results erroneously assigning to irrelevant documents. The idea of this proposed method, is to detect error-prone terms and to find similar words for each term. A parameter is defined which calculates the probability for occurring errors in the error-prone words. To recognize similar words for each specific term, based on a criterion called average detection rate (ADR) and levenshtein distance criterion, some candidates are chosen as the initial similar words set. And then, a conversion probability is defined based on the conversion rate (CR) and the noisy channel model (NCM) and the words with higher probability based on a threshold level are selected as the final similar words. In the retrieval process, these words are considered in the search step in addition to the base word. Implementation result shows a significant improvement up to 30% of F-measure in information retrieval method with consideration of this pre-processing.

Keyword: Information retrieval, Speech recognition, Document, Query, Levenshtein Distance

یا مرتبط‌ترین سندها به پرس‌وجوی داده‌شده را به‌ترتیب رتبه^۶، به کاربر برمی‌گرداند.

در بازیابی صدا، پرس‌وجو می‌تواند به دو شکل کلی داده شود [19]. در شکل نخست که به آن پرس‌وجو با نمونه گفته می‌شود، از یک نمونه صوتی به‌عنوان پرس‌وجو استفاده می‌شود. در این حالت هدف کاربر این است که پوشه‌های صوتی را که شامل نمونه صوتی ورودی یا نزدیک به آن هستند، پیدا کند. بسیاری از سامانه‌های بازیابی موسیقی و بازیابی گفتار آهنگین از این روش استفاده می‌کنند. در حالت خاصی از این روش، کاربر یک آهنگ یا موسیقی را زمزمه می‌کند و سامانه بازیابی، موسیقی یا آهنگ‌های مشابه با آن را از یک پایگاه داده یافته و فهرست آن‌ها را به کاربر برمی‌گرداند. به این روش پرس‌وجو با زمزمه^۷ می‌گویند [9].

در شکل دوم که به آن پرس‌وجو با کلمه کلیدی^۸ گفته می‌شود، پرس‌وجو، یک نمونه متنی شامل یک یا چند کلمه کلیدی است. در این روش که بیشتر در بازیابی صداهای گفتاری به کار می‌رود، هدف کاربر این است که پوشه‌های گفتاری را که شامل آن کلمات کلیدی یا در موضوعی نزدیک به آن‌ها هستند، پیدا کند. درحالی‌که با صداهای غیر گفتاری سروکار داریم، پرس‌وجوی متنی می‌تواند ویژگی‌ها یا توصیفی از صوت باشد که در قالب کلمات بیان می‌شود.

برای بازیابی صداهای گفتاری به‌طور معمول از ترکیبی از فناوری‌های بازشناسی گفتار^۹ و بازیابی اطلاعات استفاده می‌شود؛ یعنی صداهای گفتاری ابتدا به متن معادل تبدیل شده و سپس عملیات بازیابی بر روی متن انجام می‌شود [18]. در شکل زیر شمای کلی یک سامانه بازیابی صدای گفتاری نمایش داده‌شده است:

۱- مقدمه

اگر چه امروزه استفاده از سامانه‌های رایانه‌ای، جستجو و بازیابی اطلاعات^۱ را تسهیل کرده است؛ ولی جستجو و بازیابی، تاکنون به‌طور عمده در محتواهای متنی انجام می‌پذیرفته است؛ درحالی‌که نیاز به استخراج اطلاعات از محتواهای غیر متنی مانند صدا نیز احساس می‌شود، هرچند این نیاز تا حدی با تولید فراداده^۲ برای محتواهای صوتی رفع می‌شود، ولی تولید فراداده کاری زمان‌بر و پرهزینه است. بنابراین به دنبال روش یا روش‌هایی هستیم که بدون نیاز به فراداده و تنها با استفاده از محتوای خود صدا و مشخصات آکوستیکی آن، جستجو و بازیابی اطلاعات را در آن انجام دهد. به این روش‌ها، بازیابی مبتنی بر محتوا^۳ گفته می‌شود که بازیابی صدا یکی از این موارد محسوب می‌شود.

مسئله بازیابی صدا را می‌توان به‌صورت زیر تعریف کرد: یک مجموعه از مستندات صوتی^۴ در اختیار داریم؛ می‌خواهیم از بین این مجموعه مستندات، سند یا سندهایی را پیدا کنیم که درجه شباهت و یا میزان ارتباط و نزدیکی آن با یک نمونه صدای مورد نظر (و یا توصیفی از آن صدا) بیشتر باشد.

نمونه صدا (یا توصیفی از آن) را که به دنبال سندهایی مرتبط با آن در مجموعه هستیم، در اصطلاح پرس‌وجو^۵ نامیده می‌شود. با این تعریف، یک سامانه بازیابی صدا به‌طور کلی به این صورت عمل می‌کند که کاربر درخواست خود را به‌صورت پرس‌وجو به سامانه می‌دهد. سامانه بازیابی صدا با روش‌های خاص خود میزان شباهت و یا میزان ارتباط و نزدیکی پرس‌وجوی داده‌شده را، با تک‌تک سندهای صوتی موجود در بایگانی می‌سنجد و سپس فهرستی از شبیه‌ترین و

¹ Information retrieval

² Metadata

³ Content base retrieval

⁴ Audio documents

⁵ Query

⁶ Rank

⁷ Query by humming

⁸ Query by keyword

⁹ Speech recognition

مروری بر روش‌ها و کارهای مشابه در این زمینه خواهیم داشت. بخش چهارم به توضیح الگوریتم‌های پیشنهادی اختصاص دارد. نتایج پیاده‌سازی و تحلیل‌های مربوطه در بخش پنجم آورده شده است و در نهایت، بخش ششم به نتیجه‌گیری و ارائه پیشنهادها برای انجام کارهای آینده اختصاص دارد.

۲-پیشینه پژوهش

در مقدمه مقاله حاضر، توضیحاتی در مورد مفهوم بازیابی صداهای گفتاری ارائه و بیان شد که تمرکز مقاله حاضر، روی بازیابی صداهای گفتاری است که به متن تبدیل شده‌اند. مشکل عمده‌ای که در این جا وجود دارد، وجود خطای بازنشاسی گفتار است که موجب می‌شود سندی که واقعاً مرتبط است، نامرتب تشخیص داده شود. مشابه این مشکل، در بازیابی متون عادی نیز ممکن است در اثر مواردی چون وقوع خطاهای املایی یا تایپی، اتفاق بیفتد.

یک راه‌کار کلی برای حل این مشکل، گسترش پرس‌وجو^۱ است. در این روش، در کنار کلمه اصلی پرس‌وجو، تعدادی کلمه مشابه، در نظر گرفته می‌شود و اسنادی که شامل این کلمات باشند نیز جزو اسناد مرتبط در نظر گرفته می‌شوند. مشابهت در این جا می‌تواند از نوع معنایی و مترادف بودن و یا ساختاری باشد. علاوه بر گسترش پرس‌وجو، روش‌های اصلاح پرس‌وجو نیز که به‌طور معمول به‌صورت تصحیح خطاهای تایپی یا املایی انجام می‌شود نیز مورد استفاده قرار گرفته است.

در حوزه بازیابی متون حاصل از بازنشاسی گفتار، از بین دو روش گسترش و اصلاح پرس‌وجو، در بیشتر موارد، روش نخست استفاده شده است. یافتن کلمات مشابه نیز در برخی مقالات، بر مبنای استفاده از قواعد نحوی (مانند [4]) و در بعضی دیگر بر مبنای ویژگی‌های آکوستیکی (مانند [14]) انجام گرفته است.


علاوه بر دو روش یادشده، روش‌های دیگری نیز ارائه شده است. به‌عنوان مثال، صرف‌جو در [2]، روشی بر مبنای گسترش اسناد ارائه کرده است. در این روش، ابتدا کلمات مهم و کلیدی هر سند، شناسایی و سپس، به‌ازای هر کلمه، تعدادی کلمه مشابه، استخراج می‌شوند. بدین ترتیب، درواقع به‌ازای هر سند، تعدادی سند مشابه به دست آمده است. به‌علت تعداد بسیار زیاد این اسناد مشابه، در مرحله بعد، تعداد محدودی از مناسب‌ترین آن‌ها انتخاب می‌شوند و

^۱ Query expansion

در این مقاله، تمرکز ما روی همین سامانه است، یک مشکل عمده این است که سامانه‌های بازنشاسی گفتار همواره با درصدی خطا همراه هستند. در نتیجه ممکن است، سندی مرتبط با پرس‌وجو باشد، اما به‌علت خطای بازنشاسی گفتار و در نتیجه وجود کلمات دچار اشکال در متن، به‌عنوان سند مرتبط تشخیص داده نشود.

در این مقاله، روشی جدید برای بازیابی اطلاعات گفتاری بر اساس گسترش پرس‌وجو ارائه شده است. در این جا، ایده این بوده که روش بازیابی نسبت به رخداد خطای بازنشاسی گفتار تا اندازه‌ای مقاوم باشد. برای پیاده‌سازی، انجام سه گام، پیشنهاد شده است.

گام نخست، تشخیص احتمال خطای کلمات است. گام دوم، یافتن کلمات مشابه کلمه مورد پرس‌وجو است؛ یعنی کلمات جایگزینی را که ممکن است پرس‌وجو بعد از بروز خطا به آن‌ها تبدیل شود، شناسایی می‌کنیم. نکته مهم این است که در این جا فقط یافتن کلمات مشابه کافی نیست؛ بلکه از آن جا که یک کلمه بعد از بروز خطا با احتمال متفاوت به کلمات دیگر تبدیل می‌شود، محاسبه احتمال تبدیل نیز اهمیت زیادی دارد. گام سوم، بازیابی اسنادی که دچار خطای بازنشاسی شده‌اند با استفاده از یک روش بازیابی اطلاعات است. این کار با اضافه کردن پارامترهای به‌دست آمده در دو گام قبلی، به یک روش بازیابی صورت می‌گیرد.



(شکل-۱): ساختار کلی یک سامانه بازیابی اطلاعات گفتاری با

استفاده از کلمات کلیدی

(Figure-1): The general structure of a speech information retrieval system using keywords

برای تحقق و پیاده‌سازی اجزای مختلف این ایده، الگوریتم‌هایی پیشنهاد شده است که به‌زودی توضیح داده خواهند شد.

کلیه بخش‌های روش پیشنهادی به‌طور کامل پیاده‌سازی شده‌اند. نتایج حاصل، بیان‌گر کارایی بهتر این الگوریتم نسبت به الگوریتم‌های معمول بازیابی اطلاعات است. بخش‌های مختلف این مقاله به شرح زیر ساماندهی شده است: در بخش دوم پیشینه پژوهش و در بخش سوم

که در آن $w \in D$ کلمه صحیح مورد نظر است و $s \in \Sigma^*$ کلمه اشتباه است.

به عنوان مثال، برای حروف الفبای انگلیسی، $\Sigma = \{a, b, c, \dots, y, z, A, B, \dots, Z, \dots\}$ یک زیرمجموعه از Σ^* ، واژگانی از کلمات معتبر انگلیسی خواهد بود. اشتباهات و خطاهای مختلفی وجود دارد که شامل موارد مهم زیر است.

۱- حذف ناخواسته حروف (برای مثال leter به جای letter)، اضافه شدن تصادفی حروف (برای مثال، mistake به جای misstake)

۲- جابه جایی حروف (برای مثال، recieved به جای received)

۳- جانشینی حروف (برای مثال، fimate به جای finite)

برای ساخت ماتریس کانال نوفه ای Γ ، ما باید احتمال هر اشتباه (یعنی $\Pr(s|w)$) را به ازای تمامی $w \in D$ و $s \in \Sigma^*$ داشته باشیم. این احتمال ممکن است از طریق فاصله لونشتاین بین w و s محاسبه شود.

هدف مدل کانال نوفه ای، یافتن کلمه صحیح از بین کلمات اشتباه ورودی است. برای انتخاب کلمه صحیح، نیاز به یک تابع تصمیم^۷ است. تابع تصمیم $\sigma: \Sigma^* \rightarrow D$ ، تابعی است که کلمات اشتباه را گرفته و کلمه صحیح را برمی گرداند. روش های ساخت این تابع تصمیم شامل شیوه بیشترین احتمال (ML^۸)، شوهی بیشترین احتمال پسین (MAP^۹) و روش کمترین فاصله ویرایشی^{۱۰} است.

در یک سیستم احتمالی، ما می خواهیم $\hat{w} = \arg\max_w P(w|s)$ را بیابیم. به بیان دیگر، در این جا کلمه اشتباه s را در اختیار داریم. می خواهیم از بین کلیه کلمات موجود در فرهنگ لغت، کلمه ای را انتخاب کنیم که موجب شود این احتمال، بیشینه شود. این کلمه را $\hat{w}$ می نامیم. بر اساس قانون بیز^{۱۱}، می دانیم رابطه زیر وجود دارد:

$$P(w|s) = P(s|w)p(w) \quad (1)$$

در مدل پیشنهادی، فرض شده است، کلمه ای را با احتمال $P(w)$ به عنوان پرس و جو به سامانه بازبایی،

در نهایت این اسناد، به همراه اسناد اصلی، در فرایند بازبایی، شرکت می کنند.


در مقاله حاضر، روشی ترکیبی بر مبنای گسترش و اصلاح پرس و جو، ارائه شده است. در این روش، ابتدا کلمه پرس و جو مورد ارزیابی قرار می گیرد. اگر این کلمه، جزو کلمات مستعد برای خطای بازشناسی، تشخیص داده شود، کلمات مشابه این پرس و جو نیز در نظر گرفته می شود. در بخش ادبیات موضوع با مفهوم مدل کانال نوفه ای، آشنا می شویم که آشنایی با این مفهوم، قبل از بیان روش پیشنهادی ضروری است.

۳- ادبیات موضوع

۳-۱- مدل کانال نوفه ای (NCM)^۱

NCM چارچوبی است که در خطایاب املائی^۲، پاسخ دهنده خودکار سوالات^۳، بازشناسی گفتار^۴ و ماشین ترجمه^۵ استفاده شده است. در این مدل، هدف، یافتن کلمات صحیح جایگزین، بر اساس یک کلمه داده شده است. اگر NCM درست آموزش داده شود، با احتمال زیادی می تواند کلمه صحیح را حدس بزند [8]، [13]، [11]. از آن جا که یکی از مدل های استفاده شده در روش پیشنهادی، همین مدل است، این روش را با جزئیات بیشتر در این قسمت توضیح می دهیم.

تعریف: حروف الفبای Σ داده شده است، Σ^* را به عنوان یک مجموعه ای از تمامی رشته های محدود بر روی Σ در نظر بگیرید. فرض کنید فرهنگ لغت D زیر مجموعه ای از Σ^* باشد ($D \subset \Sigma^*$).



(شکل-۲): شمای کلی مدل کانال نوفه ای در اصلاح خطای جملات
(Figure-2): Overview of Noisy Channel Model in Error correction of sentences

ماتریس کانال نوفه ای^۶، ماتریسی به شکل زیر است:

$$\Gamma_{ws} = \Pr(s|w)$$

¹ Noisy Channel Model (NCM)

² Spell checkers

³ question answering

⁴ Speech recognition

⁵ Machine translation

⁶ Noisy channel

⁷ Decision function

⁸ Maximum Likelihood

⁹ Maximum a posteriori probability

¹⁰ Minimum edit distance

¹¹ Bayes' rule

۴-۱- الگوریتم روش پیشنهادی

ورودی: (۱) یک سری سند که متون موجود در آن‌ها از بازیابی گفتار به دست آمده است. (۲) یک واژه‌نامه از واژگان زبان مورد نظر.

ا- ماتریس وقوع^۱ مربوط به اسناد را به دست بیاور

ب- به ازای هر کلمه پرس‌وجو q

ب-۱- با استفاده از یک مجموعه داده آموزشی، $P_e(q)$ ، احتمال این‌راکه کلمه q دچار خطای بازیابی بشود محاسبه می‌کنیم. توضیح بیشتر راجع به محاسبه $P_e(q)$ را در بخش ۵ (پایه‌سازی و تحلیل نتایج) بیان خواهیم کرد.

ب-۲- کلمات مشابه با این کلمه و احتمال تبدیل هر یک از آن‌ها به کلمه پرس‌وجو را محاسبه کن.

ب-۳- احتمال‌های تبدیل محاسبه‌شده در مرحله قبل را مرتب کن.

ب-۴- بر مبنای یک مقدار آستانه کلمات مشابه دارای احتمال تبدیل بیشتر را به پرس‌وجو اضافه کن، وزن هر یک از کلمات پرس‌وجوی اضافه‌شده را متناسب با احتمال تبدیل محاسبه‌شده در مرحله قبل برای آن در نظر بگیر.

ب-۵- به هر یک از کلمات فعلی موجود در پرس‌وجو (اعم از کلمه اولیه و کلمات مشابه اضافه‌شده به پرس‌وجو)، وزنی اختصاص بده، وزن کلمه اولیه، بر مبنای نوع روش بازیابی تعیین می‌شود^۲. وزن کلمات مشابه متناسب با احتمال تبدیل محاسبه‌شده در مرحله ب-۱ است.

ج- روش بازیابی دلخواهی را روی اسناد اعمال کن.

خروجی: اسناد مرتبط با کلمه پرس‌وجوی اصلی و کلمات مشابه آن.

در شکل (۳)، نمودار روش پیشنهادی آمده است. در ادامه، مراحل مختلف الگوریتم با تفصیل بیشتری، توضیح داده خواهند شد.

۴-۲- مفهوم ماتریس وقوع و نحوه محاسبه آن در اسناد

ماتریس وقوع، ماتریسی است که سطر و ستون آن به ترتیب، واژگان و اسناد می‌باشند (این ترتیب می‌تواند معکوس هم باشد). اگر واژگان خاصی در یک سند مشخص

^۱ Occurrence matrix

^۲ واضح است که در اکثر روش‌های بازیابی، وزنی به کلمه پرس‌وجو داده می‌شود.

می‌دهیم اما کانال نوفه‌ای، کلمه s را به‌عنوان کلمه مشابه پرس‌وجو (که به احتمال دچار خطا شده است)، با احتمال $P(s|w)$ پیشنهاد می‌کند. در نتیجه، تابع تصمیم ما به صورت $\hat{w} = \arg\max_w P(s|w)p(w)$ خواهد بود.

برای محاسبه $\hat{w}$ ، روشی در [11] پیشنهاد شده است. در این روش، پارامترهای مدل، به‌دفعات تا رسیدن به وضعیت ایستا، تخمین زده می‌شوند.

در این قسمت، فقط مدل NCM اولیه توضیح داده شد. مدل‌های احتمالی کانال کامل‌تری نیز ارائه شده است. توانوا و مور در [17] نشان دادند که ترکیب مدل NCM بر مبنای آوا و مدل NCM بر مبنای حرف، بازدهی بیشتری را نسبت به هر کدام از آن‌ها به‌تنهایی دارد. روش ترکیبی، تصحیح را با دقت ۹۵/۵۸٪ و سه گزینه بهتر با دقت ۹۹/۵۰٪ جواب را پیدا می‌کند [8].

۴-۲- روش پیشنهادی

در این بخش، روش پیشنهادی توضیح داده می‌شود. این روش، بر مبنای گسترش پرس‌وجو است. به‌طور مشخص، پیش‌پردازشی به روش بازیابی اضافه کرده‌ایم که کلمات، احتمال وقوع خطا در آن‌ها، فهرست کلمات مشابه و احتمال تبدیل به آن‌ها را محاسبه می‌کند. در نهایت، کلمه صحیح، کلمه‌ای می‌شود که کمترین احتمال وقوع خطا را داشته باشد.

گسترش پرس‌وجو در روش‌ها و پژوهش‌های گذشته بر اساس گسترش اسناد مشابه صورت گرفته است؛ که یک فرایند زمان‌بر، ناکارآمد و پرهزینه به‌شمار می‌رود. حال آن‌که کارایی و سرعت از عوامل مهم در یک سامانه بازیابی گفتار به شمار می‌رود. در روش پیشنهادی، علاوه‌بر بهبود در نتایج بازیابی، بهبود خوبی در سرعت بازیابی حاصل شده است. به این نحو که به‌جای گسترش اسناد بازیابی، تنها پرس‌وجو گسترش داده می‌شود. با تعریف و تنظیم منطقی وزن کلمه اصلی در پرس‌وجو و کلمات مشابه بهبود خوبی در شناسایی خطاهای بازیابی گفتار حاصل کردیم. این روش، مستقل از نوع روش بازیابی است؛ یعنی می‌توان آن را به‌عنوان یک پیش‌پردازش قبل از هر روش بازیابی قرار داد. در ادامه، ابتدا الگوریتم کلی روش بیان شده و سپس مراحل مختلف این الگوریتم به تفصیل توضیح داده می‌شود.

نخست صحیح یا غلط بودن کلمه را مشخص کند و دوم این که در صورت غلط بودن معادل صحیح را حدس بزند. برای محاسبه احتمال تبدیل نیز روش زیر پیشنهاد می‌شود:

ا- به ازای کلمه‌ی پرس و جوی w ، تمام کلماتی را که فاصله‌ی لونشتاین آن‌ها با w از حد مشخصی کمتر است، به دست بیاور. به این کلمات، کلمات نامزد می‌گوییم.

فاصله‌ی لونشتاین، معیاری برای اندازه‌گیری تفاوت میان دو رشته است. این فاصله یکی از الگوریتم‌های مهم محاسبه فاصله ویرایشی به حساب می‌آید. فاصله لونشتاین میان دو رشته به صورت حداقل تعداد ویرایش‌های مورد نیاز برای انتقال از یک رشته به دیگری تعریف می‌شود. عملیات مجاز شامل «درج»، «حذف» و «جانشینی» تک‌نویسه است. مثال‌هایی از کلمات با فاصله لونشتاین برابر یک در زیر آمده است:

طبق ← طبقه (با درج «ه» به انتهای کلمه)

باز ← راز (با جانشینی «ر» به جای «ب»)

درونی ← درون (با حذف «ی» از انتهای کلمه)

برای آشنایی بیشتر با تئوری این روش به [16] و [6] مراجعه نمایید.

ب- به ازای هر کلمه نامزد c ،

ب-1- $p(w|c)$ ، احتمال تبدیل کلمه نامزد c به w را محاسبه کن. این پارامتر، نشان‌دهنده‌ی احتمال تبدیل w به c است. در این مقاله، دو فرمول برای محاسبه چنین احتمالی ارائه شده است. لازم به ذکر است که این دو فرمول با هم معادل نیستند؛ بلکه هر یک به صورت شهودی، به نحوی نشان‌دهنده‌ی احتمال تبدیل یادشده هستند.


فرمول ۱: ابتدا پارامتر نرخ تبدیل را به صورت زیر محاسبه و سپس با هنجارسازی آن، $p(w|c)$ را محاسبه می‌کنیم.

$$CR_{c,w} = \left(\frac{1}{L_{c,w}} \right) \times \left(\frac{L_w}{L_c} \right)^\alpha \quad (2)$$

که در این رابطه، $L_{c,w}$ ، فاصله‌ی لونشتاین در نظر گرفته شده بین c و w است. همچنین، L_c ، تعداد نویسه‌های کلمه نامزد، L_w ، تعداد نویسه‌های کلمه پرس و جوی و α ، میزان تأثیر پارانتر دوم است.

در ادامه، هنجارسازی را نیز به صورت زیر انجام می‌دهیم:

وجود داشت، درایه مربوط به آن در ماتریس وقوع، یک و اگر واژگان در سند وجود نداشت این درایه، صفر خواهد شد. همچنین می‌توان به جای یک کردن درایه ماتریس در صورت وجود، مقدار درایه را برابر تعداد تکرار واژگان در سند مورد نظر دانست. توجه به این نکته حائز اهمیت است که برای کل اسناد ورودی، تنها یک ماتریس وقوع به دست آورده می‌شود.



(شکل-۳): نمودار جعبه‌ای الگوریتم پیشنهادی
(Figure-3): Flowchart of the proposed algorithm

۳-۴- محاسبه کلمات مشابه و احتمال تبدیل

آن‌ها به کلمه پرس و جوی

اگر به ازای یک کلمه موجود در اسناد:

- بتوان تعیین کرد که آیا کلمه صحیح است (دچار خطای بازشناسی نشده است) یا خیر
- و اگر دچار خطا شده معادل صحیح کلمه چه می‌باشد؛

آن‌گاه به طور کامل تأثیر خطاهای بازشناسی از بین رفته است. واضح است که انجام این کار به شکل صد درصد امکان‌پذیر نیست؛ لیکن باید تلاش کرد تا حد امکان این کار انجام شود. هدف از این قسمت از الگوریتم، انجام چنین کاری است.

به طور طبیعی راه کار ارائه شده باید هر دو نکته اشاره شده در بالا را پوشش دهد؛ یعنی با دقت مناسبی

$ins[x, y]$ ، تعداد رخداد عمل درج حرف y بعد از حرف x است. به بیان دیگر تعداد دفعاتی که در اثر خطا، y بعد از x درج و کلمه صحیح به کلمه نادرست دیگری تبدیل شده است.

$sub[x, y]$ ، تعداد رخداد عمل جانشینی حرف y به جای حرف x است. به بیان دیگر تعداد دفعاتی که در اثر خطا، y جانشین حرف x شده و کلمه صحیح به کلمه نادرست دیگری تبدیل شده است.

$count[x]$ و $count[xy]$ به ترتیب نشان دهنده تعداد تکرار x و xy در مجموعه‌ی داده‌های آموزشی^۳ مدل NCM است. ج- تا این جا، به ازای کلمه پرس‌وجو، تعدادی کلمه نامزد در نظر گرفته شده و برای هر یک، عددی به نام CR محاسبه شده است. اکنون مقادیر CR کلمات نامزد مربوط به پرس‌وجوی مورد نظر را به صورت نزولی مرتب کن.

د- بر مبنای یک مقدار آستانه، کلمات کاندید متناظر با CRهای بزرگ‌تر را به عنوان کلمات نامزد نهایی در نظر بگیر. این کلمات را در اصطلاح کلمات مشابه کلمه پرس‌وجو می‌نامیم.

ه- اکنون در هنگام جستجو واضح است که اگر خود کلمه پرس‌وجو عیناً یافت شود، انطباق حاصل است. همچنین اگر یکی از کلمات مشابه پرس‌وجو نیز در متن یافت شد، می‌گوییم در این موضع، خطای بازشناسی اتفاق افتاده و این کلمه مشابه را نیز انطباق در نظر می‌گیریم.

الگوریتم بالا، درواقع دو نکته ارائه شده در چند خط قبل را پوشش می‌دهد؛ یعنی هم موضع خطای بازشناسی را حدس می‌زند و هم کلمه جایگزین را پیشنهاد می‌دهد. هرچه فاصله لونشتاین بین کلمه پرس‌وجو و کلمه نامزد کمتر باشد، شباهت دو کلمه به یکدیگر بیشتر است. از طرف دیگر هرچه طول کلمه نامزد کوچک‌تر باشد، احتمال آن که پرس‌وجو بتواند جایگزین مناسب برای آن باشد، کمتر است؛ لذا پراتز دوم نیز در نظر گرفته شده است. در این رابطه، در بخش پیاده‌سازی، توضیحات دقیق‌تری خواهیم داد.

۴-۴- مرتب‌سازی احتمال‌های تبدیل مربوط به کلمات مشابه

در این مرحله، احتمالات تبدیل مربوط به کلمات مشابه را که در مرحله ب-۲ به دست آمده‌اند، به ترتیب نزولی مرتب

$$P(w|c) = \frac{CR_{c,w}}{\max(CR_{c1,w})} \quad (3)$$

به روش پیاده‌سازی شده توسط دو رابطه اخیر، در اصطلاح روش CR می‌گوییم.

فرمول ۲: در این رابطه، از مطالبی که در بحث مدل کانال نوفه‌ای بیان شد، استفاده می‌کنیم. در NCM رابطه زیر را در نظر گرفتیم.

$$P(w|c) = P(c|w) \times P(w) \quad (4)$$

در این جا سعی می‌کنیم، برای محاسبه $P(w)$ و $P(c|w)$ در کاربرد خاص موضوع مقاله، روابطی را ارائه دهیم.

محاسبه $P(w)$ با استفاده از رابطه زیر انجام می‌شود.

$$P(w) = \frac{freq(w) + 0.5}{N} \quad (5)$$

c ، کلمه نامزد است و w ، کلمه‌ای است که دچار خطای بازشناسی شده و قرار است، کلمه مشابه برای آن یافت شود.

برای محاسبه احتمال تبدیل، ابتدا باید احتمال کلمه w محاسبه شود. در ضمن $freq(w)$ تعداد رخداد کلمه w در مجموعه اسناد است. با توجه به روش باکس و تیائو می‌توان با استفاده از یک احتمال اولیه به یک توزیع پسین^۱ برای یک واژه رسید. میزان در نظر گرفته شده برای این مقدار، تعداد رخداد به علاوه 0.5 است. این احتمال را تخمین احتمال مورد انتظار^۲ می‌نامند [7]. احتمال شرطی $p(c|w)$

$$p(c|x) = \begin{cases} \frac{del[w_{i-1}, w_i]}{count[w_{i-1}, w_i]}, & \text{if deletion} \\ \frac{ins[w_{i-1}, x_i]}{count[w_{i-1}]}, & \text{if insertion} \\ \frac{sub[x_i, w_i]}{count[w_i]}, & \text{if substitution} \\ \frac{trans[w_i, w_{i+1}]}{count[w_i, w_{i+1}]}, & \text{if transposition} \end{cases} \quad (6)$$

$del[x, y]$ ، تعداد رخداد عمل حذف حرف y بعد از x است. به بیان دیگر تعداد دفعاتی که در اثر خطا، y بعد از x حذف و کلمه صحیح به کلمه نادرست دیگری تبدیل شده است.

^۱ Posterior Distribution

^۲ Expected Likelihood Estimate

^۳ training data set

می‌کنیم. با توجه به واضح بودن این مرحله، درباره آن توضیح بیشتری نمی‌دهیم.

۴-۵- اضافه کردن کلمات مشابه به پرس‌وجو

در این مرحله بر مبنای یک مقدار آستانه تصمیم می‌گیریم که کدام یک از کلمات مشابه را همراه با پرس‌وجو در نظر بگیریم (معنای همراه بودن و تأثیر آن به‌زودی روشن می‌شود). بعد از در نظر گرفتن مقدار آستانه، کلمات مشابه با احتمال تبدیل بزرگ‌تر را همراه با پرس‌وجو در نظر می‌گیریم.

۴-۶- اختصاص وزن به کلمه پرس‌وجو و کلمات مشابه

آنچه که تا به این مرحله انجام گرفته، بخش اعظمی از پیش‌پردازش قبل از اعمال روش بازیابی است. جهت تکمیل این پیش‌پردازش تنها یک نکته باقی مانده و آن تعیین وزن کلمات مشابه در گسترش پرس‌وجو است. این وزن در فرایند بازیابی نقش اساسی دارد و اگر وزن آن به‌صورت غیر منطقی تعیین شود، اثر پیش‌پردازش انجام گرفته تا این مرحله را خنثی می‌سازد. اگر وزن‌دهی کلمات مشابه را به خود بازیابی محول کنیم، روش بازیابی بدون توجه به احتمال تبدیل آن‌ها، وزنی را اختصاص می‌دهد که هیچ تأثیر در شناسایی خطاها نخواهد داشت و مثل این می‌ماند که ما به‌طور دقیق کلمات مشابه را به‌عنوان عبارت پرس‌وجو وارد کرده باشیم. سؤال اساسی آن است که چگونه این وزن را بر اساس پارامترهای پیش‌پردازش به‌گونه‌ای تنظیم کنیم که باعث بهبود در بازیابی خطاهای بازشناسی شود؟ جهت پاسخ به این سؤال باید رابطه احتمال تبدیل کلمه مشابه و احتمال خطای کلمه اصلی پرس‌وجو را با وزن کلمه پرس‌وجو، روشن سازیم.

وزن کلمات مشابه، باید متناسب با وزن کلمه پرس‌وجو باشد، زیرا در اصل، ما به دنبال کلمه پرس‌وجو هستیم نه کلمات مشابه؛ احتمال خطای کلمه اصلی پرس‌وجو نیز در وزن کلمات مشابه تأثیرگذار است. هرچه احتمال خطای کلمه پرس‌وجو بیشتر باشد، وزن کلمات مشابه باید به وزن کلمه اصلی پرس‌وجو نزدیک‌تر باشد. در بین کلمات مشابه نیز کلمه‌ای که احتمال تبدیل بیشتری را دارد، باید وزن بیشتری داشته باشد. بر اساس تعریف بیان‌شده وزن کلمه مشابه در پرس‌وجو به‌صورت زیر تعریف می‌شود.

$$Weight_w(c) = P(w|c) \times Weight(w) \times p_e(c) \quad (7)$$

در این معادله، $P(w|c)$ ، همان است که در رابطه (۴) تعریف شده است و $p_e(c)$ ، احتمال آن است که کلمه c دچار خطای بازشناسی بشود. $weight_w[c]$ ، وزن کلمه نامزد c به‌ازای کلمه پرس‌وجوی w است. $weight_w[c]$ ، وزنی است که روش بازیابی به کلمه پرس‌وجوی w می‌دهد.

۴-۷- اعمال بازیابی

در انتها، یک روش بازیابی دلخواه اعمال می‌شود. الگوریتم ارائه‌شده در این مقاله، هیچ محدودیتی روی نوع روش قرار نمی‌دهد و درواقع به مثابه یک پیش‌پردازش برای بازیابی به حساب می‌آید.

۵- پیاده‌سازی و تحلیل نتایج

در این قسمت از مقاله، ابتدا مجموعه داده مورد استفاده و محیط پیاده‌سازی توضیح داده می‌شود و سپس به بررسی و تحلیل کارایی روش پیشنهادی و مقایسه آن با روش‌های دیگر خواهیم پرداخت.

۵-۱- توصیف مجموعه داده

برای انجام این پژوهش نیاز به یک مجموعه از اسناد گفتاری همراه با متن اصلی اسناد و متن بازشناسی‌شده این اسناد بود. برای تبدیل اسناد گفتاری به متن معادل آن‌ها از مدل‌های آکوستیک مبتنی بر واج استفاده شده است [3]. مدل‌های آکوستیک مبتنی بر واج توسط دادگان فارسی‌دات بزرگ آموزش داده شدند. دادگان فارسی‌دات بزرگ توسط پژوهشگاه توسعه فناوری‌های پیشرفته خواجه نصیرالدین طوسی گردآوری شده و شامل ۱۴۰ ساعت گفتار از ۱۰۰ گوینده مختلف است. نیمی از این دادگان گفتاری (۷۰ ساعت) با استفاده از یک میکروفون دسک‌تاپ و بقیه با سه میکروفون دیگر ضبط شده است [1]. به‌منظور آموزش مدل‌های آکوستیک، داده آموزشی از سیگنال‌های ضبط‌شده با میکروفون دسک‌تاپ انتخاب شده است. داده آزمون نیز پاره‌گفتار^۱ از این دادگان است که از مجموعه آموزش جدا شده‌اند. مجموعه آزمون از هفت گوینده مختلف انتخاب شده و درمجموع حدود ۱,۵ ساعت است.

¹ Utterance

برنامه‌نویسی، نرم‌افزار Visual Studio 2013 است. برای ارزیابی کارایی از معیار اندازه F³ استفاده کرده‌ایم.

۵-۳- جزئیات پیاده‌سازی

یک روش خوب بازیابی خطای بازیابی، باید در مقابل هر نوع پرس‌وجو به‌خوبی عمل کند؛ چون در پرس‌وجو، هم ممکن است، کلمه‌ای دچار خطا باشد و هم کلمه‌ای صحیح باشد. اگر کلمه‌ای دچار خطا باشد، روش، علاوه‌بر شناسایی کلمات صحیح، می‌بایست اسنادی را که دچار خطا شده‌اند، بازیابی کند و اگر کلمه صحیح باشد، روش باید حداقل به خوبی بازیابی معمولی عمل کرده و نتایج را بدتر نسازد. جهت کاهش خطاهای ناشی از بازیابی گفتار، سه گام را باید طی نمود:

- گام نخست، تشخیص احتمال خطای کلمات است.
- گام دوم، یافتن کلمات مشابه، متناسب با کلمه‌ی مستعد خطا است. مشخص ساختن فهرستی از کلمات جایگزینی که ممکن است کلمات مستعد خطا، بعد از بروز خطا به آن‌ها تبدیل شوند (ما فهرستی از این کلمات را کلمات مشابه نامیده‌ایم). تنها یافتن کلمات مشابه کافی نیست، بلکه از آن‌جا که یک کلمه بعد از بروز خطا، با احتمال متفاوت به کلمات دیگر تبدیل می‌شود، محاسبه احتمال تبدیل اهمیت زیادی دارد.
- گام سوم، بازیابی اسنادی است که دچار خطای بازیابی شده‌اند. این کار با اضافه کردن پارامترهای به‌دست‌آمده در دو گام قبلی، به یک روش بازیابی صورت می‌گیرد.

۵-۳-۱- محاسبه احتمال خطای کلمات پرس‌وجو

ما باید بتوانیم با احتمال خوبی تشخیص دهیم که کلمه پرس‌وجو تا چه اندازه مستعد خطای بازیابی است. این گام از آن جهت اهمیت دارد که اگر روش، به اشتباه کلمات مشابه‌ای را به پرس‌وجویی که احتمال خطای بازیابی آن کم است، اضافه کند، بازیابی در انتخاب اسناد، دچار خطا می‌شود و اثر منفی بر معیارهای بازیابی خواهد داشت. این احتمال از فرمول زیر محاسبه می‌شود:

$$P_e(q) = \frac{\text{count}_e(q)}{\text{count}(q)} \quad (8)$$

q، هر کلمه‌ای از مجموعه دادگان آموزشی می‌تواند باشد. نسبت تعداد دفعاتی که این کلمه دچار خطای بازیابی شده به کل تکرارهای آن در دادگان، نشان‌دهنده احتمال خطای کلمه است. در پیش‌پردازش قبل از بازیابی به‌زای تمام کلمات واژه‌نامه این احتمال محاسبه می‌شود.

³ F-measure

مجموعه‌ی واژگان نیز شامل شصت‌هزار کلمه بوده است؛ در سامانه بازیابی از مدل تری‌گرام^۱ به‌عنوان مدل زبانی و به‌صورت اتصال نیمه [10] استفاده شده است. برای آموزش مدل تری‌گرام از پیکره متنی زبان فارسی (شامل حدود ۱۰۰ میلیون کلمه) استفاده شده است [5] و روش هموارسازی کاتز^۲ بر روی آن اعمال شده است [12].

در واقع در این پژوهش از این مجموعه آزمون به‌عنوان مجموعه داده برای بازیابی اطلاعات گفتاری، استفاده شده است. این مجموعه داده شامل تعداد ۷۵۳ سند بوده و تعداد جملات هر یک از این اسناد بین ۱ تا ۱۲ جمله است. دقت بازیابی کلمات این مجموعه در حدود ۸۰ درصد است. بعد از حذف کلمات توقف از میان کل اسناد، ۳۹۶ سند، شامل خطای بازیابی هستند. اطلاعات مربوط به خطا، شامل شماره سندی که خطا در آن رخ داده، کلمه‌ای که دچار خطا شده و نیز کلمه‌ای که در اثر خطا به آن تبدیل شده است، در قالب یک فایل متنی از قبل موجود است.

جهت یافتن کلمات مشابه و محاسبه احتمال تبدیل آن‌ها، نیاز به یک واژگان اولیه است، این واژگان اولیه می‌تواند یک واژگان کامل از کلمات پرکاربرد فارسی باشد و یا تنها شامل کلمات کلیدی مؤثر در بازیابی باشد. در یک سامانه بازیابی اطلاعات، سایر کلمات که در بازیابی مؤثر نیستند، (مانند کلمات توقف) و به‌طورمعمول در تمامی اسناد تکرار می‌شوند، در نظر گرفته نمی‌شوند؛ زیرا تأثیر منفی بر آمار و اطلاعات استخراج‌شده از تحلیل خطاهای بازیابی داشته و از دید بازیابی نیز کم‌ارزش هستند.

به‌منظور کارایی بهتر در محاسبات مربوط به بازیابی و معیارهای آن، از یک واژه‌نامه اولیه که نزدیک به ده‌هزار کلمه پر کاربرد فارسی را در خود دارد، استفاده کرده‌ایم.

۵-۲- محیط اجرا و ابزارهای استفاده‌شده

تمامی مراحل الگوریتم (روش‌های بازیابی- برداری، روش پیشنهادی، کشف خطاهای بازیابی، روش NCM، محاسبه معیارهای بازیابی برداری) به‌صورت عملی کدنویسی شده‌اند و زبان برنامه‌نویسی مورد استفاده C# است.

محیط آزمون و اجرای روش، یک سامانه رایانه با CPU Core i5 به میزان حافظه ۴ گیگابایت است. برای اجرای سریع‌تر و بهره‌وری بیشتر، کدنویسی به‌نحوی انجام شده است که پردازش‌ها به‌صورت موازی صورت گیرد. محیط

¹ Trigram

² Katz

این بخش مهم‌ترین بخش روش پیشنهادی است. شناسایی دقیق و کامل کلمات مشابه امکان‌پذیر نیست؛ اما می‌توان با درصد خوبی کلمات مشابه را شناسایی کرد. برای یافتن کلمات مشابه که خروجی نهایی این مرحله است، باید از کلمات واژه‌نامه، کار را آغاز کرد و بر اساس معیارهای مشخصی، آن‌ها را محدود ساخت تا به کلمات مشابه برسیم، این کار یک فرایند سه مرحله‌ای است.

مرحله نخست: یافتن کلمات کاندید، از طریق فیلتر کردن کلمات واژه‌نامه بر اساس فاصله ویرایشی لونشتاین.

مرحله دوم: محاسبه احتمال تبدیل کلمات نامزد.

مرحله سوم: انتخاب بهترین کلمات نامزد.

قبل از پرداختن به جزئیات هر یک از مراحل بالا، به معرفی معیاری جهت سنجش کارایی آن‌ها می‌پردازیم.

برای اندازه‌گیری و نمایش میزان اثربخشی روش‌ها در تشخیص کلمات نامزد، نیاز به یک معیار است. در این قسمت به دنبال یافتن یک چنین معیاری هستیم. بدین‌منظور معیاری به نام متوسط نرخ تشخیص (ADR) تعریف می‌کنیم (از این پس تا پایان پژوهش جهت سادگی و کوتاهی به آن نرخ تشخیص گفته می‌شود)

$$ADR = \frac{\sum_{e=1}^n |TWe \cap RWe|}{|TWe| + |FWe|} \quad (9)$$

که در آن e ، کلمه‌ای است که دچار خطای بازشناسی شده، RWe^1 ، مجموعه کلمات مشابه واقعی برای کلمه e ام (کلمه‌ای که دچار خطای بازشناسی می‌شود، به‌اشتباه به کلمه یا کلمات مشابه دیگری تبدیل می‌شود که ما آن‌ها را کلمات مشابه واقعی می‌نامیم)، TWe^2 ، مجموعه کلمات مشابه به‌دست‌آمده از طریق روش پیشنهادی برای کلمه e ام و n ، تعداد کل خطاهای بازشناسی از مجموعه داده‌های اسناد بازشناسی‌شده، می‌باشند. FWe^3 نیز، مجموعه کلمات مشابه نادرست تشخیص داده‌شده، به‌زای کلمه e ام است.⁴

۵-۳-۳- یافتن کلمات نامزد

در این پژوهش، از الگوریتم لونشتاین برای یافتن کلمات نامزد استفاده شده است. به دو دلیل الگوریتم لونشتاین برای این کار مناسب تشخیص داده شد. دلیل نخست، وجود رابطه

¹ real related word (RW)

² true related word (TW)

³ false related word (FW)

⁴ با مطالعه مقالات و منابع مرتبط با موضوع، رابطه‌ای که بیانگر میزان اثربخشی روش‌ها باشد، مشاهده نشد؛ لذا روش ADR، ارائه شد که به‌طور شهودی، فرمول مناسبی به‌نظر می‌رسد.

معناداری بین تعداد خطاهای بازشناسی و فاصله لونشتاین است. همان‌طور که در قبل در بخش توصیف داده اشاره شد، ۳۹۶ سند، دارای خطای بازشناسی هستند. بعد از حذف کلمات توقف و تحلیل‌های صورت‌گرفته روی این اسناد، تعداد آن‌ها در جدول (۱) بیان شد.

دلیل دوم اطلاعاتی است که نشان می‌دهد، بیشتر خطاها ناشی از سه عملیات جانشینی، درج و حذف است که هر سه در محاسبه الگوریتم لونشتاین لحاظ می‌شوند. برای رسیدن به این واقعیت، توزیع خطاها را برای هر دو الگوریتم دامروا- لونشتاین و لونشتاین به‌دست آوردیم. نتایج نشان می‌دهد، انتقال دو حرف مجاور تأثیر زیادی در خطاهای بازشناسی ندارد؛ بنابراین فاصله لونشتاین، معیار مناسبی برای انتخاب کلمات نامزد، تشخیص داده شد و از آن‌جا که روی هم رفته ۷۲٪ خطاها در فاصله لونشتاین‌های ۱ و ۲ می‌باشند، توان خود را بر روی این بخش از خطاها متمرکز ساخت و کلمات نامزد را کلماتی از واژه‌نامه در نظر می‌گیریم که فاصله لونشتاین آن‌ها نسبت به کلمه خطا، کوچک‌تر یا مساوی ۲ باشد.

۵-۳-۴- محاسبه احتمال تبدیل کلمات نامزد

فاصله لونشتاین به‌عنوان یک فیلتر اولیه برای حذف کلمات نامزد نامرتبب مناسب است، اما کافی نیست. در ابتدای امر، هر کلمه مستعد خطا ممکن است به هر یک از کلمات دیگر واژه‌نامه تبدیل شود؛ اما احتمال تبدیل آن‌ها متفاوت است؛ برای بسیاری از کلمات واژه‌نامه این احتمال صفر و تنها برای درصد اندکی از آن‌ها این احتمال بزرگتر از صفر است. هدف ما در این قسمت، محاسبه احتمال تبدیل برای کلمات نامزد به‌دست‌آمده از مرحله قبل است. بدیهی است که محاسبه دقیق این احتمال امکان‌پذیر نیست؛ اما با معیار ADR نشان خواهیم داد که احتمال تبدیل را تا حد معقولی درست محاسبه کرده‌ایم. برای محاسبه احتمال تبدیل، از دو روش استفاده کرده‌ایم و سپس آن‌ها را با یکدیگر مقایسه می‌کنیم.

روش اول، محاسبه احتمال تبدیل با استفاده از CR می‌باشد. قبل از محاسبه احتمال تبدیل CR ابتدا فرمول (۲) را روشن‌تر می‌سازیم. این فرمول از دو قسمت تشکیل شده است. قسمت اول، معکوس فاصله لونشتاین کلمه کاندید با کلمه پرس‌وجو یا همان کلمه اولیه می‌باشد. دلیل آن هم با توجه به مطالب بیان‌شده مشخص است. زیرا بیشتر کلماتی که دچار خطا می‌شوند به کلماتی با فاصله لونشتاین پایین تبدیل می‌شوند. لذا یک رابطه عکس بین

پرواز از ریشه ها

(جدول-۱): تعداد خطاها بر حسب فاصله لونشتاین

(Table-1): The number of errors in terms of Loewenstein distance

فاصله لونشتاین	1	2	3	4	4	8	جمع کل خطاها
تعداد خطاها	181	103	79	26	6	1	396
بر حسب درصد	45.71%	26.01%	19.95%	6.57%	1.52%	0.25%	100%

(جدول-۲): نمونه‌ای از محاسبه احتمال تبدیل به‌ازای CR، برای کلمه "همکار"

(Table-2): An example of calculating the probability of conversion based on CR, for the word "Hamkar"

کلمه اصلی (w) = "همکار"	حداکثر فاصله لونشتاین = 2		
کلمه نامزد (x)	$CR_{x,w}$	$\max(CR_{x,w})$	$P_w(x)$
امکان	1.9%	6.4%	29.6875%
همراه	1.9%	6.4%	29.6875%
همکاری	6.4%	6.4%	100%
همواره	3.2%	6.4%	50%
.	.	.	.
مزار	0.3%	6.4%	14.0625%


(جدول-۳): نمونه‌ای از محاسبات مربوط به احتمال تبدیل

(Table-3): An example of calculating the probability of conversion

کلمه اصلی (w): "درونی"			حداکثر فاصله لونشتاین = ۲		
کلمه نامزد (x)	Errors	$P(x w)$	$P(w)$	Distance	$P(x w)P(w)$
روند	del[#>#']-sub[د=>ی]-	3.62/E-3	3.31/E-2	2	1.19/E-6
دینی	del[د=>در]-sub[ی=>و]-	.	9.94/E-2	2	.
درون	del[ن=>نی]-	04.2017%	1.66/E-1	1	6.95/E-3
دروس	del[س=>ی]-sub[و=>ون]-	.	3.31/E-2	2	.
دارویی	ins[د=>دا]-sub[ن=>ن]-	.	3.31/E-2	2	.
فروند	sub[د=>ف]-sub[ی=>ی]-	.	3.31/E-2	2	.
کنونی	sub[د=>ک]-sub[ر=>ن]-	.	3.31/E-2	2	.
گروهی	sub[د=>گ]-sub[ن=>ن]-	1.74/E-4	9.94/E-2	2	1.72/E-7
ورودی	sub[د=>و]-sub[ن=>ن]-	.	3.31/E-2	2	.
درختی	sub[و=>خ]-sub[ن=>ن]-	2.28/E-4	3.31/E-2	2	7.54/E-8

۴-۵- نتایج بازیابی

ایده اصلی بازیابی خطاهای بازشناسی در بخش قبل بیان شد. در این قسمت، فقط به ارائه نتایج بسنده می‌کنیم. تا این مرحله توانستیم پارامترهای مؤثر در شناسایی کلمات مشابه را برای هر دو مدل پیشنهادی شناسایی کنیم. جهت ارزیابی کارایی الگوریتم پیشنهادی، از یک روش بازیابی برداری با طرح وزن‌دهی استاندارد Inc.ltc [15]، بهره گرفتیم. وزن کلمه اصلی پرس‌وجو توسط روش بازیابی و وزن کلمات مشابه نیز طبق معادله (۷) مشخص می‌شود. برای ارزیابی کارایی روش ارائه‌شده، نتایج را یک بار با



(شکل-۶): نمودار ADR و سطح آستانه برای دو مدل CR و NCM (Figure-6): ADR - Threshold chart for CR and NCM models

^۱ علامت # به معنای نویسه null است، یعنی حرفی که وجود ندارد و برای نمایش حذف یک حرف از ابتدای کلمه یا درج یک حرف در ابتدای کلمه استفاده شده و بیشتر دلیل تکنیکی دارد.

الگوریتم بازیابی، چند سند را به عنوان اسناد مرتبط برگرداند. در تمامی مدل‌ها، بیشینه فاصله لונشتاین برای تعیین کلمات نامزد، ۲ در نظر گرفته شده است (دلیل آن در قبل در بخش ۳-۳-۵ توضیح داده شد).

۵-۴-۱- تعیین پارامترهای مدل

برای مقایسه دقیق و آسان، ابتدا پارامترهای هر یک از مدل‌ها را معرفی کرده و اعدادی را که قرار است، نتایج بر اساس آن‌ها مقایسه شوند مشخص می‌سازیم.


اعداد مناسب برای پارامترهای مؤثر در مدل NCM و CR، در قبل در بخش ۵-۳-۵ به دست آمدند. این پارامترها عبارتند از سطح آستانه و π بهترین کلمات نامزد که به ترتیب با T و M نمایش خواهیم داد. اعداد مناسب برای هر یک از آن‌ها $T=0.7$ و $M=1$ است.

پارامترهای مؤثر در مدل CR عبارتند از ضریب تأثیر و سطح آستانه که به ترتیب با α و T نشان داده شده‌اند و اعداد مناسب برای آن‌ها $\alpha=2$ و $T=0.9$ است.

۵-۴-۲- مقایسه نتایج اجرا، بدون در نظر گرفتن سطح آستانه

سه معیار «صحت^۱»، «فراخوانی^۲» و «معیار F» را برای این مدل‌ها با مقادیر N مختلف و پرس‌وجوهای مختلف، محاسبه کردیم. در شکل‌های ۷ و ۸، پارامتر اندازه F، به ازای دو حالت پرس‌وجوی تصادفی و پرس‌وجوی خطادار، نمایان است.

همان‌گونه که ملاحظه می‌شود، الگوریتم توسعه‌یافته در هر دو مدل (NCM و CR)، در مقابل پرس‌وجوهای تصادفی تا ۹٪ و در مواجهه با پرس‌وجوهای خطادار تا ۳۰٪ بهبود را نسبت به بازیابی ساده نشان می‌دهد.



(شکل-۷): نمودار F-N در مقابل پرس‌وجوی تصادفی

(Figure-7); F - N chart for random query

¹ Precision
² recall

اضافه کردن پیش‌پردازش و یک بار بدون اضافه کردن آن به بازیابی عادی، براساس پرس‌وجوهای مختلف به دست آورده و با هم مقایسه می‌کنیم تا بهبود و کارایی الگوریتم پیشنهادی را نشان دهیم. بازیابی معمولی را الگوریتم اولیه^۱ و روش پیشنهادی را الگوریتم توسعه‌یافته^۲ می‌نامیم. باتوجه به آنکه روش ارائه شده، درواقع یک پیش‌پردازش به شمار می‌آید و همچنین به علت عدم وجود روشی مشابه که گسترش پرس‌وجو را بر مبنای ویژگی‌های موجود در بازشناسی گفتار (احتمال خطای بازشناسی) انجام دهد، ارزیابی کارایی به صورت توضیح داده شده، انجام گرفته است.

همان‌طور که در ابتدای این بخش اشاره کردیم، یک روش خوب بازیابی خطای بازشناسی، باید در مقابل هر نوع پرس‌وجو به خوبی عمل کند. برای ارزیابی کارایی الگوریتم توسعه‌یافته، از سه نوع پرس‌وجو استفاده کردیم.

- پرس‌وجوی بدون خطا: از کلماتی تشکیل یافته که دچار خطای بازشناسی نشده‌اند. انتظار می‌رود الگوریتم توسعه‌یافته در مقابل این گونه پرس‌وجوها بدتر از الگوریتم اولیه عمل نکند.

- پرس‌وجوی خطادار: پرس‌وجویی است که کلمات آن از بین کلماتی انتخاب می‌شوند که دچار خطای بازشناسی شده‌اند. انتظار می‌رود الگوریتم توسعه‌یافته در مقابل این گونه پرس‌وجوها بهتر از الگوریتم اولیه عمل کند.

- پرس‌وجوی تصادفی: کلمات این نوع پرس‌وجو به صورت تصادفی از واژگان انتخاب می‌شوند و ممکن است هر کدام از آن‌ها، کلمه خطا یا بدون خطا باشد. انتظار می‌رود الگوریتم توسعه‌یافته در مقابل این گونه پرس‌وجوها بهتر از الگوریتم اولیه عمل کند.

الگوریتم توسعه‌یافته با الگوریتم اولیه با هر سه نوع پرس‌وجو، مقایسه شده است. پرس‌وجوها، ۱۲۰ کلمه‌ای در نظر گرفته شده‌اند و نشان دادیم که الگوریتم توسعه‌یافته انتظارات را به خوبی برآورده می‌کند.

برای مقایسه نمونه‌های مختلف از نمودار F استفاده شد. برای این منظور، به تکرار محاسبات با تعداد مختلف اسناد بازیابی نیاز شده بود. در این پژوهش این عدد را با N نمایش می‌دهیم. به بیان دیگر عدد N نشان می‌دهد که

¹ Main algorithm
² Expanded algorithm

پرس و جو جهت رتبه بندی اسناد استفاده می کند. فاصله کسینوسی اسناد با پرس و جوی وارد شده، بین ۰ تا ۱/۵۸ است. برای تفکیک اسناد مرتبط و نامرتبط، یک سطح آستانه نیاز است. در این قسمت، سطح آستانه مناسب برای الگوریتم توسعه یافته و الگوریتم اولیه را به دست آورده و نتایج را بر اساس آن دوباره اجرا کرده و با یکدیگر مقایسه می کنیم.

برای محاسبه سطح آستانه، ابتدا رتبه های اسناد را به اعدادی با توزیع شبه نرمال تبدیل می کنیم و رتبه های جدید به دست آمده را به عنوان رتبه های اسناد در نظر می گیریم. فرمول تبدیل رتبه ها به توزیع شبه نرمال به صورت زیر است:

$$Rank_{new}(q, d) = \frac{Rank(q, d) - \mu}{\sigma} \quad (10)$$

که در این فرمول منظور از $Rank_{new}(q, d)$ ، عددی است که روش بازیابی در ازای پرس و جوی مشخص q ، به عنوان امتیاز یا رتبه برمی گرداند. μ ، میانگین و σ ، انحراف معیار رتبه های اسناد است. بدیهی است که میانگین اسناد به دست آمده برابر صفر و انحراف معیار آن ها برابر یک خواهد بود. از بین اسناد با رتبه های جدید، اسنادی را که رتبه آن ها از صفر بیشتر است، به عنوان اسناد مرتبط در نظر می گیریم.

بار دیگر نتایج را بر اساس سطح آستانه اجرا می کنیم. نتایج حاصل در شکل (۱۰) و جدول (۴) آمده است.




(شکل-۱۰): نمودار مقایسه معیار F براساس پرس و جوی متفاوت


(Figure-10): F benchmark Comparison chart based on different queries

بر اساس اطلاعات این شکل و جدول، معیار F برای الگوریتم توسعه یافته، در برابر انواع پرس و جوها بهتر از الگوریتم اولیه عمل می کند. این در حالی است که بدون استفاده از سطح آستانه، الگوریتم اولیه در برابر پرس و جوی بدون خطا، بهتر از الگوریتم توسعه یافته عمل می کرد؛ اما با استفاده از سطح آستانه دیگر این گونه نیست. جدول (۵)، بهبود الگوریتم توسعه یافته را در معیارهای F، صحت و فراخوانی، بهتر

در شکل (۹) نتایج در مقابل پرس و جوی بدون خطا در حالتی که از N به جای سطح آستانه استفاده شود، متفاوت است. الگوریتم توسعه یافته در مقابل این نوع پرس و جوها بدتر عمل می کند؛ اما در مرحله بعد وقتی از سطح آستانه استفاده می کنیم، نشان خواهیم داد که الگوریتم توسعه یافته در مقابل این نوع پرس و جوها نیز، با سطح آستانه بهتر عمل می کند. نکته دیگر آن که الگوریتم اولیه به ازای $N=2$ در مقابل پرس و جوهایی از این قبیل، خوب عمل می کند.



(شکل-۸): نمودار F-N در مقابل پرس و جوی خطا دار
(Figure-8): F - N chart for erroneous query



(شکل-۹): نمودار F-N در مقابل پرس و جوی بدون خطا
(Figure-9): F - N chart for correct query

۴-۳-۵- مقایسه نتایج اجرا با در نظر گرفتن سطح آستانه

در قسمت قبل برای مقایسه دو مدل، تعداد نتایج بازیابی (N) را تعیین می کردیم. در کاربردهای واقعی بازیابی اطلاعات، مدل ها باید به صورت خودکار، تعداد نتایج بازیابی شده را مشخص کنند. برای این منظور نیاز به تعریف سطح آستانه برای امتیاز اسناد، در الگوریتم بازیابی اطلاعات است. الگوریتم بازیابی از فاصله کسینوسی بین بردار اسناد و

۷-مراجع

7-Reference

- [۱] شیخ زادگان، جواد، بیجن خان، محمود، "داده‌های گفتاری زبان فارسی"، در دومین کارگاه پژوهشی زبان فارسی و رایانه، دانشگاه تهران، ۱۳۸۵، صفحات ۲۴۷-۲۶۱.
- [1] J. Sheykhzadegan, M. Bijankhan, (2007). "Persian language speech data", in The Second Persian Language and Computer Research Workshop, University of Tehran, 2007, pp. 247-261.
- [۲] صرفجو، سعید، "چارچوبی جدید برای بازیابی اطلاعات به منظور استفاده در بازیابی صدای گفتاری فارسی"، پایان‌نامه منتشرشده کارشناسی ارشد، دانشکده فنی و مهندسی دانشگاه قم، قم، ایران، ۱۳۹۰.
- [2] Sarfjoo, S., "A New Framework for Information Retrieval to use in Persian Spoken Document Retrieval", Published master's dissertation, Faculty of Technical and Engineering of University of Qom, Qom, Iran, 2012.
- [۳] بحرانی، محمد، "به‌کارگیری ساختارهای وابسته به بافت در بازشناسی گفتار پیوسته مبتنی بر مدل مخفی مارکوف"، پایان‌نامه منتشرشده کارشناسی ارشد، دانشکده فنی و مهندسی دانشگاه صنعتی شریف، تهران، ایران، ۱۳۸۲.
- [3] Bahrani, M., "Using Context Dependent Structures in Continuous Speech Recognition based on Hidden Markov Model", Published master's dissertation, Faculty of Technical and Engineering of Sharif University of Technology, Tehran, Iran, 2004.
- [4] Abberley, D., and et. al., "THE THISL BROADCAST NEWS RETRIEVAL SYSTEM", in ESCA Tutorial and Research Workshop (ETRW) on Accessing Information in Spoken Audio, 1999, pp. 14-19.
- [5] Bijankhan, M., and et. al., "Lessons from Creation of a Persian Written Corpus: Peykare", Language Resources and Evaluation, vol. 45(2), pp. 143-164, 2011.
- [6] Black, Paul E., ed., "Levenshtein distance Dictionary of Algorithms and Data Structures", in National Institute of Standards and Technology, U. S., 14 August 2008. [online]. Available: www.nist.gov
- [7] Box, G., and Tiao, G., Bayesian Inference in Statistical Analysis. Massachusetts, Addison-Wesley, 1973.

نشان می‌دهد. اطلاعات جدول نشان‌دهنده بهبود بر حسب درصد می‌باشد.

۶-نتیجه‌گیری و پیشنهادها

در این مقاله، یک پیش‌پردازش روی روش‌های بازیابی اطلاعات حاصل از متون بازشناسی‌شده گفتاری، ارائه شد که به شکل ترکیبی از اصلاح و گسترش پرس‌وجو بود. ورودی‌های مسئله، اسناد متنی به‌دست‌آمده از بازشناسی گفتار و پرس‌وجو، جهت یافتن اسناد مرتبط با کلمه پرس‌وجو بودند. در بخش ۵، نتایج پیاده‌سازی آورده شد و تحلیل‌های لازم روی آن صورت گرفت. دو مدل برای شناسایی کلمات مشابه و احتمال تبدیل آن‌ها معرفی شد. برای سنجش کارایی مدل‌ها، معیار ADR تعریف و پارامترهای مؤثر در هر مدل شناسایی شد؛ سپس اندازه هر یک از پارامترها در جهت کارایی بهتر تعیین شد. روش ارائه‌شده به‌عنوان یک پیش‌پردازش قبل از بازیابی برداری قرار گرفت. درضمن برای سنجش کارایی از معیارهای صحت، فراخوانی و F استفاده شد. برای مقایسه کارایی، یکبار روش بازیابی عادی و یکبار روش بازیابی همراه با پیش‌پردازش ارائه‌شده، به مجموعه داده اعمال شدند. مشخص شد الگوریتم توسعه‌یافته با سطح آستانه، بهتر از الگوریتم اولیه عمل می‌کند. همچنین مدل NCM عملکرد بهتری نسبت به مدل CR دارد. روش پیشنهادی با استفاده از مدل NCM، در مقابل خطاهای بازشناسی، حدود ۳۰٪ بهبود در معیار F را ایجاد کرد. در آن، ترکیبی از روش بازیابی برداری، مدل NCM، مدل CR و الگوریتم لونتستاین، جهت شناسایی خطاهای حاصل از بازشناسی به‌کار برده شد و به نتایج مثبتی رسیدیم.

ارائه نتایج بهتر و دقیق‌تر، نیازمند مجموعه داده وسیع‌تر و بیشتری در این زمینه است. هر چه داده‌های بیشتری برای آموزش مدل وجود داشته باشد، می‌توان نتایج دقیق‌تری را به‌دست آورد. کمبود داده‌های اولیه ناشی از خطای بازشناسی فارسی، جهت آموزش بهتر مدل‌ها، از مشکلات پیش رو است. انتظار می‌رود که الگوریتم توسعه‌یافته، در بخش محاسبه احتمال خطای کلمات پرس‌وجو، با ترکیب مدل‌های زبانی و مدل‌های آکوستیکی، نتایج بهتری داشته باشد که پژوهش‌های بیشتری را در آینده می‌طلبد.



روح الله دیانت تحصیلات کارشناسی ارشد و دکترای خود را به ترتیب در سال‌های ۱۳۸۲ و ۱۳۸۹ در دانشگاه صنعتی شریف به اتمام رسانده و هم‌اکنون استادیار دانشگاه قم (گروه مهندسی کامپیوتر و فناوری اطلاعات) است. زمینه اصلی فعالیت وی، پردازش چندرسانه‌ای (صدا، تصویر و ویدئو) است. نشانی رایانامه ایشان عبارت است از:

rouhollah.dianat@gmail.com



مرتضی علی‌احمدی تحصیلات کارشناسی خود را در رشته علوم رایانه در دانشگاه قم، در سال ۱۳۹۱ و همچنین تحصیلات کارشناسی ارشد خود را در رشته مهندسی فناوری اطلاعات، در دانشگاه قم، در سال ۱۳۹۳ به پایان رسانده است. زمینه پژوهشی و مورد علاقه وی، پردازش صدا و تصویر است. نشانی رایانامه ایشان عبارت است از:

morteza.ali.ahmadi@gmail.com



محمد یحیی اخلاقی تحصیلات کارشناسی خود را در رشته علوم رایانه در دانشگاه قم به انجام رسانده است. همچنین تحصیلات کارشناسی ارشد را در رشته مهندسی فناوری اطلاعات، در دانشگاه قم در سال ۱۳۹۲ به اتمام رسانده است. او هم اکنون به عنوان مربی در مؤسسه آموزش عالی خاتم النبیین کابل مشغول به کار است. نشانی رایانامه ایشان عبارت است از:

yahya.akhlaghi@gmail.com



باقر باباعلی تحصیلات کارشناسی ارشد و دکترای خود را در رشته هوش مصنوعی در دانشگاه صنعتی شریف و در سال‌های ۱۳۸۲ و ۱۳۸۹ به اتمام رسانده است. هم‌اکنون ایشان، عضو هیأت علمی گروه آمار و علوم رایانه پردیس علوم دانشگاه تهران هستند. زمینه‌های اصلی مورد علاقه ایشان، بازیابی اطلاعات و پردازش گفتار است. نشانی رایانامه ایشان عبارت است از:

bagher.bababli@gmail.com

- [8] Brill, E., and Moore, R., "An Improved Error Model for Noisy Channel Spelling Correction", in 38th Annual meeting of Association for Computational Linguistics, Hong Kong, 2000.
- [9] Ghias, A., and et. al., "Query by Humming: Musical Information Retrieval in an Audio Database", in ACM Multimedia Conference, San Francisco, CA, USA, 1995, pp. 231-236.
- [10] Harper, M. P., and et. al., "Integrating Language Models with Speech Recognition", in AAAI94 Workshop on the Integration of Natural Language and Speech Processing, Seattle, Washington, USA, 1994, pp. 139-146.
- [11] Jurafsky, D., and Martin, J., Speech and Language Processing: An Introduction to Natural Language Processing, second ed. Prentice Hall, Pearson Education International, 2000.
- [12] Katz, S., "Estimation of Probabilities from Sparse Data for the Language Model Component of a Speech Recognizer", IEEE Transactions on Acoustics, Speech and Signal Processing, vol 35(3), pp. 400-401, 1987
- [13] Kukich, K., "Techniques for Automatically Correcting Words in Text", ACM Computing Survey, vol 24, pp. 377-439, 1992.
- [14] Logan, B., and Van Thong, J., "Confusion-based query expansion for OOV words in spoken document retrieval", in 7th International Conference on Spoken Language Processing, Denver, Colorado, USA, 2002.
- [15] Manning, D. C., and et. al., An Introduction to Information Retrieval. Cambridge University Press, 2009.
- [16] Navarro, G., "A guided tour to approximate string matching", ACM Computing Surveys, vol 33(1), pp. 31-88, 2001.
- [17] Toutanova, K., Moore, R. C., "Pronunciation Modeling for Improved Spelling Correction", in 40th Annual meeting of Association for Computational Linguistics, Philadelphia, Pennsylvania, 2002, pp. 144-151.
- [18] Turunen, V., "Spoken Document Retrieval", in Department of Computer Science and Engineering Helsinki University of Technology, 2006.
- [19] Zhang, T., and Jay Kuo, C. C., "Content-based Classification and Retrieval of Audio", in 43th Annual Meeting-Conference on Advances Signal Processing, Algorithms, Architectures and Implementations, San Diego, 1998.