ارایهٔ یک پیکرهٔ پرسش و پاسخ مذهبی در زبان فارسی

یاسمن برشبان، حامد یوسفی‌نسب و سید ابوالقاسم میرروشندل*
گروه مهندسی کامپیوتر، دانشکده فنی، دانشگاه گیلان، رشت، ایران

چکیده

سامانه‌های پرسش و پاسخ، زیرشاخه‌ای از علوم پردازش زبان طبیعی و بازیابی اطلاعات محسوب می‌شوند که در چند دههٔ اخیر مورد علاقهٔ زیاد پژوهش‌گران قرارگرفته‌اند. با توجه به رشد فزایندهٔ علاقه‌مندی به این زمینهٔ پژوهشی، نیاز به دراختیارداشتن منابع داده‌ای مناسب برای آن، به‌خوبی احساس می‌شود. تاکنون اغلب پژوهش‌های صورت‌گرفته در رابطه با توسعهٔ پیکرهٔ پرسش و پاسخ در زبان انگلیسی بوده است؛ درصورتی‌که در زبان‌های دیگر مانند فارسی، نیاز شدیدی به وجود چنین پیکره‌هایی احساس می‌شود. در این مقاله، مراحل کامل توسعه یک پیکرهٔ متنی پرسش و پاسخ با نام رسائل و مسائل در زبان فارسی شرح داده خواهد شد. این پیکره شامل ۲،۱۱۸ سؤال غیرحقیقت و ۲،۰۵۱ سؤال حقیقت بوده که برای هر سؤال، متن سؤال، نوع سؤال، سختی سؤال از نظر پرسشگر و پاسخ‌دهنده، طبقه معنایی پاسخ در سطح درشت‌دانه و ریزدانه، پاسخ دقیق سؤال و شماره صفحه و پاراگراف پاسخ، نشانه‌گذاری شده است. پیکرهٔ پیشنهادی برای یادگیری کلیه مؤلفه‌های سامانه‌های پرسش و پاسخ شامل دسته‌بندی سؤال، بازیابی اطلاعات و استخراج پاسخ، مورداستفاده می‌تواند قرار گیرد و به‌صورت رایگان در دسترس پژوهش‌گران قرار دارد. در ادامه یک سامانه پرسش و پاسخ بر روی پیکره رسائل و مسائل معرفی می‌شود. نتایج نشان می‌دهد که سامانهٔ پیشنهادی توانسته است به دقت ۸۲/۲۹ و میانگین معکوس رتبه ۵۶/۷۳ درصد دست یابد. می‌توان اظهار کرد که پیکره و سامانهٔ پیشنهادی در نوع خود، نخستین پیکره و سامانهٔ مربوط به پرسش و پاسخ با چنین ویژگی‌هایی برای زبان فارسی است.

واژگان کلیدی: سامانه‌های پرسش و پاسخ، پردازش زبان طبیعی، بازیابی اطلاعات، پیکره رسائل و مسائل

Providing a Religious Corpus of Question Answering System in Persian

Yasaman Boreshban, Hamed Yousefi Nasab & Seyed Abolghasem Mirroshandel*
Computer Engineering Department, faculty of Engineering, University of Guilan, Rasht, Iran

Abstract

Question answering system is a field in natural language processing and information retrieval noticed by researchers in these decades. Due to a growing interest in this field of research, the need to have appropriate data sources is perceived. Most researches about developing question answering corpus area have been done in English so far, but in other languages as Persian, the lack of these corpora is perceived. In this article, the development of a Persian question answering corpus called Rasayel&massayel will be discussed. This corpus consists of 2,118 non-factoid and 2,051 factoid questions that for each question, question text, question type, question difficulty from questioner and responder's perspective, expected answer type in coarse-grained and fine-grained level, exact answer, and page and paraghraph number of answer are annotated. The prposed corpus can be applied to learn components of question answering system, including question classification, information retrieval, and answer extraction. This corpus is freely available for the academic purpose as well.

* نویسندهٔ عهده‌دار مکاتبات
* Corresponding author

In the following, a question answering system is presented on the Rasayel&massayel corpus. Our experimental result represents that the intended proposed system has achieved 82.29 % accuracy and 56.73 % mean reciprocal rank. It could be also claimed that this is the first ever question answering system and corpus with such features in Persian.

Keywords:Question answering system, Natural language processing, Information retrieval, Rasayel&massayel corpus

۱- مقدمه

امروزه با افزایش اطلاعات در فضای اینترنت، کاربران باید زمان زیادی را صرف یافتن اطلاعات مدنظر خود کنند. برای تسهیل این امر، سامانه‌های بازیابی اطلاعات کلاسیک درقالب موتورهای جستجو ارائه شدند. در این سامانه‌ها، کاربران پرسش‌های خود را به‌صورت زبان طبیعی مطرح می‌کنند؛ سپس موتورهای جستجو، فهرستی را از صفحات مرتبط با این سؤال برای کاربران برمی‌گردانند.

در مقابل بازیابی اطلاعات کلاسیک، سامانه‌های پرسش و پاسخ[1]معرفی‌شده‌اند [8]. در سامانه‌های پرسش و پاسخ که شکل پیچیده‌تری از سامانه‌های بازیابی اطلاعات هستند، به جای بازگرداندن کل سند، بخش خاصی از اطلاعات که مدنظر کاربر است، به‌عنوان پاسخ برگردانده می‌شود. کاربران سامانه‌های پرسش و پاسخ، علاقه‌مند به دریافت پاسخ مختصر، قابل‌فهم و صحیح هستند که این پاسخ ممکن است یک کلمه، جمله، پاراگراف، تصویر، قطعهٔ صوتی و یا یک سند کامل باشد [7-8].

در چند دههٔ اخیر، سامانه‌های پرسش و پاسخ، مورد علاقه زیاد پژوهش‌گران قرارگرفته‌اند. با توجه به رشد فزایندهٔ علاقه‌مندی به این زمینهٔ پژوهشی، نیاز به دراختیارداشتن منابع داده‌ای مناسب برای آن به‌خوبی احساس می‌شود. تاکنون اغلب پژوهش‌های صورت‌گرفته در رابطه با توسعهٔ پیکره[2]پرسش و پاسخ در زبان انگلیسی بوده است، درصورتی‌که در زبان‌های دیگر مانند فارسی، نیاز شدیدی به وجود چنین پیکره‌هایی احساس می‌شود.

در این مقاله، مراحل توسعه یک پیکره پرسش و پاسخ در زبان فارسی به‌نام رسائل و مسائل به‌تفصیل شرح داده خواهد شد. می‌توان اظهار کرد که این پیکره در نوع خود، اولین پیکره مربوط به پرسش و پاسخ با چنین ویژگی‌هایی برای زبان فارسی است که حتی با پیکره‌های انگلیسی موجود نیز می‌تواند قابل مقایسه باشد. این پیکره شامل ۲،۱۱۸ سؤال غیرحقیقت[3] و ۲،۰۵۱ سؤال حقیقت بوده که برای هر سؤال، متن سؤال، نوع سؤال، سختی سؤال از نظر پرسش‌گر و پاسخ‌دهنده، طبقه معنایی پاسخ در سطح درشت‌دانه و ریزدانه، پاسخ دقیق سؤال، شماره صفحه و پاراگرافی که پاسخ از آن استخراج شده و درجهٔ ارتباط پاسخ استخراج‌شده با سؤال در دو سطح ارتباط کامل (با مقدار ۲) و ارتباط جزئی (با مقدار ۱) نشانه‌گذاری شده است. این پیکره برای یادگیری کلیه مؤلفه‌های سامانه‌های پرسش و پاسخ شامل دسته‌بندی سؤال، بازیابی اطلاعات و استخراج پاسخ، به‌صورت رایگان مورد استفاده عموم می‌تواند قرار گیرد. در ادامه یک سامانه پرسش و پاسخ بر روی پیکره رسائل و مسائل معرفی می‌شود. نتایج نشان می‌دهد که سامانهٔ پیشنهادی توانسته ا ست به دقت ۸۲/۲۹ و میانگین معکوس رتبه ۵۶/۷۳ درصد دست یابد.

ساختار مقالهٔ پیش رو بدین شرح است: در بخش ۲، به تشریح کارهای مرتبط توسعه پیکره سامانه‌های پرسش و پاسخ می‌پردازیم. مفاهیم اولیه سامانه‌های پرسش و پاسخ در بخش ۳ بیان می‌شود. در بخش ۴، معماری سامانه‌های پرسش و پاسخ تشریح می شود. منبع داده‌ای مورد ا ستفاده برای ساخت پیکره و روند توسعه آن در بخش ۵ معرفی می‌شود. همچنین یک طبقه‌بندی سلسه‌مراتبی نوع پاسخ مورد انتظار و اجزا و ساختار پیکرهٔ پیشنهادی مطرح می‌شود. ابزار نشانه‌گذاری پیکره و وضعیت دردسترس‌بودن آن، در بخش۶ شرح داده می‌شود. در بخش ۷، یک سامانهٔ پرسش و پاسخ بر روی پیکره رسائل و مسائل معرفی و در بخش ۸، جمع‌بندی و کارهای آینده بیان می‌شود.

۲- کارهای مرتبط

در چند سال اخیر در زمینه توسعه پیکره پرسش و پاسخ در زبان انگلیسی پژوهش‌های گسترده‌ای صورت گرفته است. از جمله پیکره‌های پرسش و پاسخ انگلیسی به پیکره TREC می‌توان اشاره کرد که توسط کنفرانس سالانهٔ[4] TREC ارایه می‌شود. فعالیت این کنفرانس در زمینه سامانه‌های پرسش و

[1] Question Answering system

[2] Corpus

[3] Non-factoid

[4] Text Retrieval Conference

پاسخ از سال ۱۹۹۹ آغاز شد [22] و این پیکره در اختیار پژوهش‌گرانی که در این کنفرانس شرکت می‌کنند، قرار داده می‌شود [21]. در سال ۲۰۰۰، انجمن ارزیابی بین‌زبانی CLEF[1] تأسیس شد که سامانه‌های پرسش و پاسخ بین‌زبانی را توسعه داد. سامانه‌هایی که درآن، زبان سؤال با زبان اسناد موجود در مخزن اطلاعات، متفاوت است [12].

پیکرهٔ پرکاربرد دیگر، پیکرهٔ سؤال و جواب مقالات ویکی‌پدیا است [18]. این پیکره، حاوی سؤالات حقیقت[2] استخراج‌شده از مقالات ویکی‌پدیا، پاسخ سؤال، درجه سختی سؤال از نظر پرسش‌گر و پاسخ‌دهنده است که برای استفاده در دسترس عموم قرار دارد. پیکره‌ای دیگر برای مؤلفه دسته‌بندی سؤال[3] ارائه شده است که حاوی ۱۴،۵۰۰ سؤال به همراه برچسب است و برای هر سؤال، نوع پاسخ مورد انتظار در سطح درشت‌دانه[4] و ریزدانه[5] ذخیره شده است [11-10]. علاوه بر این پیکره‌ای حاوی هفتادهزار نمونه سؤال و جواب موجود است که پاسخ‌ها را در سطوح مختلف جمله، پاراگراف و سند نگهداری می‌کند [20].

در زبان فارسی، پیکره‌ای حاوی پنج‌هزار سؤال به‌منظور دسته‌بندی سؤال، ارائه شده که شامل سؤالاتی از مجموعه کتاب‌های درسی و برای هر سؤال، نوع پاسخ مورد انتظار در سطح درشت‌دانه و ریزدانه نگهداری شده است [16]. همچنین پیکره‌ای به‌منظور مشخص کردن موضوع[6] موجود است که این پیکره حاوی ۱۱۸ سؤال است [3] ؛ اما این تعداد سؤال، برای ارزیابی در سامانه‌های پرسش و پاسخ مناسب نیست. در زبان فارسی پیکره‌ای که بتواند برای کلیه مؤلفه‌های سامانه‌های پرسش و پاسخ، مورد استفاده قرار گیرد، وجود ندارد. در همین اواخر پیکره و سامانه‌ای در حوزه قرآن در زبان فارسی ارایه شده است[7] اما در مورد جزئیات پیاده‌سازی سامانه، منابع قابل استنادی در دسترس نیست.

البته در زبان فارسی تعدادی پیکره مناسب برای سایر زمینه‌های پژوهشی پردازش زبان طبیعی می‌توان نام برد؛ نظیر پیکره‌هایی برای نشانه‌گذاری نقش اجزای جمله[8] [4] ، تجزیه‌کردن وابستگی[9] [17]، خلاصه‌سازی[10] متن [14]، استخراج رویداد[11] [23] و تحلیل احساس[12] [1] که مورد استفاده پژوهش‌گران می‌تواند قرار گیرد.

[1] Cross language evaluation forum
[2] Factoid
[3] Question Classification
[4] Coarse-grained
[5] Fine-grained
[6] Topic Detection
[7] http://quranjooy.itrc.ac.ir/
[8] POS Tagging
[9] Dependency Parsing
[10] Summarization

۳- مفاهیم اولیه سامانه‌های پرسش و پاسخ

در فرآیند نشانه‌گذاری، مفاهیمی به‌کرّار مورد استفاده قرار می‌گیرد. در این بخش، دسته‌بندی سامانه‌های پرسش و پاسخ از نظر دامنه و انواع سؤالات سامانه‌های پرسش و پاسخ شرح داده می‌شود.

۳-۱- دسته‌بندی سامانه‌های پرسش و پاسخ از نظر دامنه

سامانه‌های پرسش وپاسخ از نظر دامنه به دودسته دامنهٔ باز[13] و بسته[14] تقسیم می‌شوند. سامانه‌هایی با دامنه بازیا نامحدود، باید انواع مختلف سؤالاتی را که توسط کاربران در زمینه‌های مختلف مطرح می‌شوند، پوشش دهند. برای مثال تمامی زمینه‌های ورزشی، مذهبی، سیاسی و هر زمینهٔ دیگری که ممکن است کاربران در مورد آن سؤال بپرسند، باید توسط سامانه پوشش داده شود[5] .

سامانه‌هایی با دامنه بسته، تنها جواب‌گوی سؤالات دریک زمینهٔ خاص هستند. برای مثال فقط سؤالات در زمینهٔ پزشکی یا سؤالات مذهبی را پاسخ‌گو خواهند بود و اغلب بر روی یک سایت خاص و یایک کتاب خاص،کار می‌کنند. عملکرد این سامانه‌ها در مقایسه با سامانه‌های دامنهٔ باز، ساده‌تر است؛ زیرا سامانه‌های پردازش زبان طبیعی اغلب می‌توانند اطلاعات آن دامنه خاص را استخراج کنند و از اطلاعات و ویژگی‌های خاص دامنه، در فرایند یافتن پاسخ مناسب بهره‌ببرند. در این سامانه‌ها، اغلب انواع محدودی از سؤالات که در آن زمینهٔ مدنظر پرکاربرد هستند، پوشش داده خواهد شد [15].

۳-۲- انواع سؤالات سامانه‌های پرسش و پاسخ

در یک سامانهٔ پرسش و پاسخ، سؤالات متنوعی توسط کاربران می‌تواند مطرح شود و برای پاسخ‌گویی به هر سؤال، لازم است از روش‌های مناسب آن سؤال استفاده شود. دسته‌بندی‌های مختلفی بر روی سؤالات صورت گرفته است، اما دسته‌بندی

[11] Event Extraction
[12] Sentiment Analysis
[13] Open Domain
[14] Closed Domain

معنایی که بیشتر موردتوجه واقع شده است، سؤالات را به هشت دسته حقیقت[1]، فهرست، تعریفی یا توصیفی[2]، فرضیه‌ای[3]، علیتی[4]، رابطه‌ای[5]، رویه‌ای[6] و تأییدی[7] تقسیم می‌کند [8].

سؤال حقیقت، به‌طورمعمول در زبان انگلیسی، با استفاده از کلمات پرسشی WH شروع می‌شود و حاوی کلمات پرسشی چه‌کسی، چه چیزی، چه وقت و کجاست. پاسخ این سؤال، یک حقیقت یا واقعیت بیان‌شده در متن و اغلب یک موجودیت عددی و یا اسمی است. برای مثال "شماره تلفن دانشگاه گیلان چیست؟" که پاسخ آن یک موجودیت عددی است.

سؤال فهرست، سؤالی است که پاسخ آن، فهرستی از موجودیت‌های متن است. برای مثال "زکات برچه‌چیزهایی واجب است؟ گندم، جو، خرما، کشمش، طلا، نقره، شتر، گاو و گوسفند. "

سؤال تعریفی، به دنبال تعریف یک لغت موجود در صورت سؤال است. برای مثال "تعریف روش‌های یادگیری ماشینی نیمه‌مربی چیست؟"

سؤال فرضیه‌ای، به اطلاعاتی در مورد یک رویداد فرضی نیاز دارد. برای مثال "اگر دانشجویی در امتحانات پایان‌ترم غیبت کند، چه اتفاقی خواهد افتاد؟"

سؤال علیتی، جویای دانستن اطلاعات و توضیحی از یک رویداد است و به‌طورمعمول با چرا آغاز می‌شود. برای مثال "چرا مردم به بیماری قند مبتلا می‌شوند؟"

سؤال رابطه‌ای، جویای ارتباط بین دو موجودیت است. برای مثال "ارتباط دانشگاه گیلان با شهر رشت چیست؟ دانشگاه گیلان در شهر رشت واقع است. "

سؤال رویه‌ای، سؤالی است که پاسخ آن، فهرستی از دستورالعمل‌ها برای انجام عملیات ذکرشده در سؤال است. برای مثال "مراحل گرفتن وضو چگونه است؟"

سؤال تأییدی، برای رویداد مطرح‌شده درصورت سؤال، به جواب بله یا خیر نیاز دارد. برای مثال "آیا پردازش زبان طبیعی، زیرشاخه‌ای از علم کامپیوتر است؟ بله"

از نگاهی دیگر، سؤالات به دو دسته کلی حقیقت و غیرحقیقت تقسیم می‌شوند. سؤالات حقیقت که پیش‌تر معرفی شدند. سؤالات غیرحقیقت[8]، اغلب حاوی پاسخ‌های طولانی هستند و پاسخ‌گویی به آن‌ها دشوارتر است. این سؤالات در زبان فارسی به‌طورمعمول حاوی کلمات پرسشی چرا و چگونه هستند [8].

[1] Factoid
[2] Definition or description question
[3] Hypothetical question
[4] Causal question
[5] Relationship question
[6] Procedural question
[7] Confirmation question

۴- معماری سامانه‌های پرسش و پاسخ

به‌طورکلی، سامانه‌های پرسش و پاسخ از سه مؤلفه اصلی پردازش سؤال[9]، بازیابی اطلاعات[10] و استخراج پاسخ[11] تشکیل می‌شوند [6-5]. معماری یک سامانهٔ پرسش و پاسخ در شکل (۱) نشان داده شده است.

۴-۱- مؤلفه پردازش سؤال

در مؤلفه پردازش سؤال، کلیه پردازش‌های لازم بر روی سؤال اعمال می‌شود تا روابط ساختاری و معنایی موجود درکلمات سؤال، استخراج شود. این مؤلفه از سه بخش تشخیص نوع سؤال، استخراج کلمات کلیدی و تشخیص نوع پاسخ مورد انتظار تشکیل شده است.

۴-۱-۱- تشخیص نوع سؤال

در این مرحله، تعیین می‌شود که سؤال مطرح شده، درکدام دسته از انواع سؤالات قرار می‌گیرد (انواع سؤالات در بخش ۳-۲ معرفی شده است). این مرحله، یکی از گام‌های ضروری و اولیه در سامانه‌های پرسش و پاسخ است. ازآنجاکه پاسخ‌گویی به سؤالات مختلف، نیازمند به‌کارگیری روش‌های فنی مختلف و مناسب با نوع سؤال است، بنابراین تشخیص درست نوع سؤال مطرح‌شده، بسیار حائز اهمیت است [2,8].

۴-۱-۲- استخراج کلمات کلیدی

یکی دیگر از مراحل مهم در پردازش سؤال، تشخیص کلمات کلیدی موجود در صورت سؤال است. تشخیص درست کلمات کلیدی موجود در سؤال، می‌تواند در بازیابی پاسخ مناسب، بسیار مفید باشد. برای مثال در سامانهٔ پرسش و پاسخ مذهبی، اگر بدانیم که یکی از کلمات کلیدی به‌کاررفته در صورت سؤال، نماز است، می‌توانیم بازهٔ مربوط به بازیابی پاسخ را بسیار محدود کنیم. به‌منظور تشخیص کلمات

[8] Non-factoid question
[9] Question Processing
[10] Information Retrieval
[11] Answer Extraction

کلیدی، از ویژگی‌های زبانی و الگوریتم‌های یادگیری ماشین استفاده می‌شود [8].

۳-۱-۴- تشخیص نوع پاسخ مورد انتظار

یک مرحله بسیار مهم در سامانه‌های پرسش و پاسخ، تشخیص طبقه معنایی پاسخ مورد انتظار است. درواقع، هدف این است که با توجه به سؤال، دریابیم که پاسخ مدنظر از این سؤال در چه طبقهٔ معنایی شخص، زمان، مکان و یا امثال آن قرار می‌گیرد [8]؛ سپس از میان پاسخ‌های منتخب که از متن استخراج شده است، پاسخ‌هایی را که مطابق با این طبقهٔ معنایی هستند، شناسایی کنیم. برای مثال، اگر با توجه به سؤال، دریابیم که نوع پاسخ مورد انتظار در مورد یک موجودیت عددی است، بازه‌ای که باید برای جواب جستجو کنیم، بسیار محدود می‌شود. برای این منظور، استفاده از روش‌های یادگیری ماشین [24] بسیار متداول است.

پژوهش‌ها نشان داده است که ۳۶,۴ درصد از خطاها در سامانه‌های پرسش و پاسخ، به‌دلیل تخمین نادرست نوع پاسخ مورد انتظار بوده است [8]. بدین جهت، تشخیص مناسب نوع پاسخ مورد انتظار، بسیار حائز اهمیت است.

(جدول-۱): طبقه‌بندی نوع پاسخ مورد انتظار
(Table-1): classification of expected answer type

درشت‌دانه	ریزدانه
ABBREVIATION	Abbreviation- expression
ENTITY	Animal – Body – Color – Creative – Currency –Disease/Medicine – Lang – Event – Food – Instrument –Letter – Other – Plant – Product – Religion – Sport – Substance – Symbol – Technique – Term – Vehicle - Word
DESCRIPTION	Definition – Description – Manner – Reason
HUMAN	Group – Individual – Title – Description
LOCATION	City – Country – Mountain – Other – State
NUMERIC	Code – Count – Date – Distance – Money – Order – Other – Period – Percent – Speed – Temp – Size – Weight

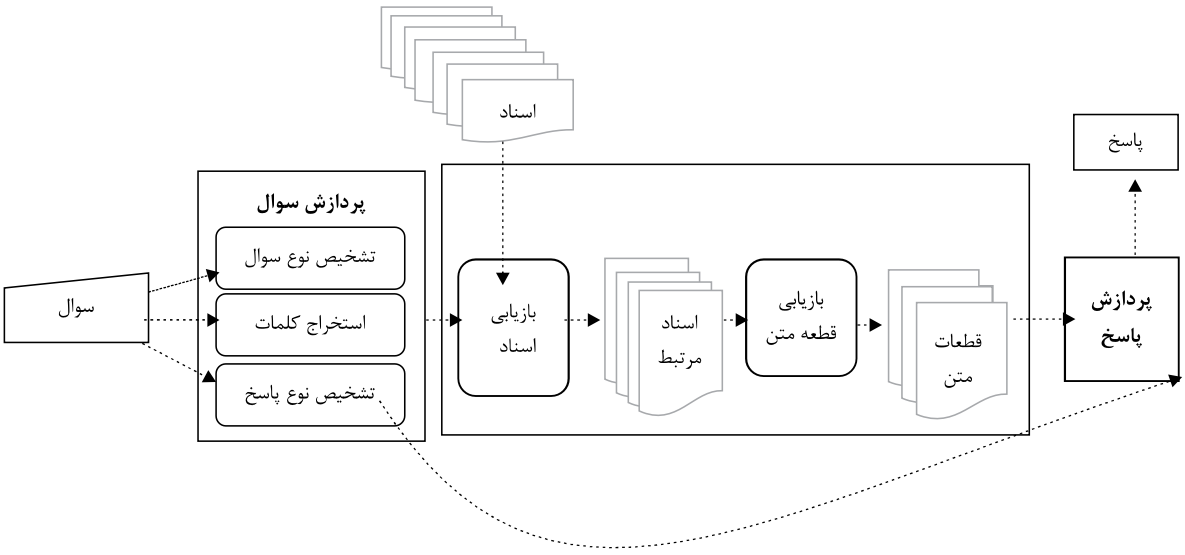

(شکل-۱): معماری سامانهٔ پرسش و پاسخ
(Figure-1): Architecture of question answering system

در سال‌های اخیر، طبقه‌بندی‌های مختلفی بر روی نوع پاسخ مورد انتظار انجام شده است. یکی از این طبقه‌بندی‌ها که مورد توجه زیاد پژوهش‌گران قرارگرفته است (هیرشمن و گایزوسکاس، ۲۰۰۲)، یک طبقه‌بندی دوسطحی بوده است که دارای شش طبقه درشت‌دانه و پنجاه طبقه ریزدانه است. این طبقه‌بندی مطابق جدول (۱) است.

۲-۴- مؤلفه بازیابی اطلاعات

این مؤلفه، به‌عنوان ورودی یک پرس‌وجو و مجموعه‌ای از اسناد را دریافت می‌کند؛ سپس توسط یک تابع، میزان ارتباط پرس‌وجو با مجموعه‌ی اسناد دریافتی را محاسبه کرده و بر این اساس به هر سند، یک رتبه تعلق می‌گیرد. به این‌ترتیب اسناد بازیابی‌شده، در فهرستی براساس امتیازشان مرتب می‌شوند [6]. در یک سامانهٔ پرسش و پاسخ، مؤلفهٔ بازیابی

سند وظیفهٔ صافی‌کردن اسناد را بر عهده دارد. به بیان دیگر در کوتاه‌ترین و قابل قبول‌ترین زمان ممکن، اسناد مرتبط به یک پرسش را بازیابی کرده و اسناد نامرتبط را جدا می‌کند. به‌طورمعمول توابعی که در بخش بازیابی سند به کار می‌روند، نسبت به توابع به‌کاررفته در بخش پردازش پاسخ، کم‌هزینه‌تر هستند تا این مرحله در سریع‌ترین زمان ممکن انجام شود [5]. مؤلفهٔ بازیابی اطلاعات در سامانهٔ پرسش و پاسخ، اهمیت ویژه‌ای دارد؛ زیرا گام‌های بعدی، تنها درصورتی‌که نتایج بازگردانده‌شده توسط مؤلفهٔ بازیابی اطلاعات صحیح و قابل‌اعتماد باشند، پاسخ صحیحی برای پرسش می‌توانند بیابند [5-7].

۳-۴- مؤلفهٔ استخراج پاسخ

مؤلفهٔ سوم، استخراج پاسخ است که در این بخش، از میان اطلاعاتی که توسط مؤلفهٔ دوم برگردانده شده، صحیح‌ترین و خلاصه‌ترین پاسخ، به‌عنوان جواب نهایی به کاربر برگردانده می‌شود. به‌طورمعمول در این مرحله به‌منظور پاسخ‌گویی به سؤالات غیرحقیقت از روش‌ها و الگوریتم‌های پیچیده‌تری استفاده می‌شود و به هر یک از پاسخ‌های برگردانده‌شده توسط مؤلفهٔ بازیابی اطلاعات، دوباره رتبه‌ای انتساب داده می‌شود و سرانجام بهترین پاسخ، برگردانده می‌شود [8] .

به‌منظور پاسخ‌گویی به سؤالات حقیقت در مؤلفه استخراج پاسخ، از تشخیص‌دهندهٔ موجودیت‌های نام‌مند[1] استفاده می‌شود تا از میان پاسخ‌های منتخب، پاسخی را برگزیند که با نوع پاسخ مورد انتظار منطبق باشد [5].

۵- توسعهٔ پیکره

در این بخش منبع داده مورد استفاده در این پژوهش مورد بررسی قرار خواهد گرفت و یک طبقه‌بندی نوع پاسخ مورد انتظار در مقاله مطرح خواهد شد. در ادامه جزئیات مربوط به اجزای پیکره به‌تفصیل بیان خواهد شد.

۵-۱- منبع داده و مراحل توسعهٔ پیکره

بدون شک، در روند توسعهٔ هر پیکره، یکی از مهم‌ترین گام‌ها، انتخاب یک منبع داده‌ای مناسب است. با توجه به اینکه تهیه یک پیکرهٔ پرسش و پاسخ با دامنه باز بسیار دشوار است، هدف ما تهیه یک پیکرهٔ پرسش و پاسخ با دامنه بسته است. یکی از زمینه‌های پرکاربرد پرسش و پاسخ در زبان فارسی، سؤالات و احکام دینی است. با توجه به ماهیت سؤالات دینی و وجود شرط‌های متعدد در سؤال و جواب، پاسخ‌گویی به این سؤالات، بسیار چالش‌برانگیز است. بدین منظور، برای توسعهٔ پیکره، این دامنه بسته، انتخاب شده است.

داده‌های خام مورد استفاده، شامل دو فایل متنی استفتائات آیت‌الله العظمی خامنه‌ای و رساله آیت‌الله العظمی مکارم شیرازی است که توسط مرجع تحقیقات علوم اسلامی(نور)[2] فراهم شده است. به‌منظور توسعهٔ پیکره، برای هر دو فایل متنی اولیه، اسنادی به شکل XML ایجاد شده است. اجزای این اسناد XML و جزئیات آن، در بخش ۷ شرح داده خواهد شد. در مرحله بعد، ابزاری به‌منظور نشانه‌گذاری طراحی شده است که در بخش ۸ توضیح داده می‌شود. باید خاطر نشان کرد که این پیکره، توسط دو نفر و در طی مدت تقریبی چهار ماه، نشانه‌گذاری شده است.

۵-۲- ارائهٔ طبقه‌بندی نوع پاسخ مورد انتظار در رساله

با توجه به اینکه هدف، کار بر روی رساله مراجع تقلید است، لازم است تغییراتی در جدول (۱) اعمال شود تا طبقه‌بندی انجام‌شده برای نوع پاسخ موردانتظار، مناسب با رساله باشد. بر این اساس، مطابق با جدول (۲)، انواع پاسخ‌های مورد انتظار، به هشت طبقه درشت‌دانه و ۳۵ طبقه ریزدانه تقسیم می‌شوند.

گروه احکام، حاوی سؤالاتی است که پاسخ آن‌ها می‌تواند، حرام، حلال، مستحب، باطل، واجب، مکروه، مباح، نجس، احتیاط مستحب، احتیاط واجب و مستحب مؤکد باشد. برای مثال "در وضو، شستن صورت برای بار سوم چه حکمی دارد؟ حرام است."

گروه تأییدی، حاوی سؤالاتی است که پاسخ آن‌ها، بله و خیر است. برای مثال "آیا خوردن گوشت خوک، حرام است؟ بله."

گروه توصیفی، شامل سؤالاتی است که پاسخ آن‌ها طولانی است که به سه زیرگروه، تعریفی، توصیفی و شیوه‌ای تقسیم می‌شوند. زیرگروه تعریفی شامل سؤالاتی است که پاسخ آن، تعریف یک عبارت به‌کاررفته درصورت سؤال است. برای مثال "تعریف آب کر چیست؟" که پاسخ آن، تعریف کلمهٔ به‌کاررفته درصورت سؤال است. زیرگروه توصیفی شامل سؤالاتی است که پاسخ آن، اطلاعات تعریفی و یا توصیف یک

[1] Named Entity Recignizer

[2] Computer Research Center of Islamic Science(CRCIS)

رویداد است. برای مثال "راه‌های شناخت مجتهد چیست؟". زیرگروه شیوه‌ای دربرگیرنده سؤالاتی است که به‌طورمعمول با کلمه کلیدی چگونه آغاز می‌شود و پاسخ آن، توضیحی در مورد نحوهٔ انجام کار است. برای مثال "چگونه وضو می‌گیریم؟".

(جدول-۲): طبقه‌بندی نوع پاسخ موردانتظار در پیکره پیشنهادی

(Table-2): classification of expected answer type in proposed corpus

درشت‌دانه	ریزدانه
احکام	حرام، حلال، مستحب، باطل، واجب، مکروه، مباح، احتیاط مستحب، احتیاط واجب، نجس، باطل، مستحب موکد
تاییدی	بله، خیر
توصیفی	تعریفی، توصیفی، شیوه‌ای،
موجودیت	حیوان، بدن، غذا، مرض-دارو، محصول، ورزش، رویداد، شخص، وسیله‌نقلیه، غیره
زمانی	اسمی، تاریخ، دوره،
مکانی	-
عددی	تعداد، فاصله، پول، نسبت، غیره
اسمی	-

گروه موجودیت، حاوی سؤالاتی است که پاسخ آن‌ها یک موجودیت است که شامل ده زیرگروه حیوان، بدن، غذا، مرض-دارو، محصول، ورزش، رویداد، شخص، و سیله‌نقلیه و غیره است. زیرگروه حیوان، شامل سؤالی است که پاسخ آن، نام یک حیوان است. برای مثال "کدام حیوانات نجس هستند؟ سگ، خوک". زیرگروه بدن، حاوی سؤالی است که پاسخ آن، یک جزء از بدن باشد. مانند، دست، صورت و پا. زیرگروه غذا دربرگیرنده سؤالی است که پاسخ آن یک مواد غذایی مانند برنج، خرما و یا امثال آن باشد. برای مثال " به چه محصولاتی، زکات تعلق نمی‌گیرد؟ برنج". زیرگروه مرض-دارو حاوی سؤالاتی است که پاسخ آن، نام بیماری یا دارو باشد. برای مثال "وجود چه بیماری در زوجین، عقد را باطل می‌کند؟ دیوانگی". زیرگروه محصول، شامل سؤالی است که پاسخ آن، یک محصول غیرغذایی به‌عنوان مثال پنبه باشد. زیرگروه ورزش، حاوی سؤالی است که پاسخ آن، یک رشتهٔ ورزشی مثلاً شنا باشد. زیرگروه رویداد، حاوی سؤالی است که پاسخ آن، یک رویداد باشد. برای مثال "در چه مواقعی، خواندن نماز آیات واجب است؟ خورشیدگرفتگی، ماه‌گرفتگی، زلزله ". زیرگروه شخص، شامل سؤالی است که پاسخ آن، یک شخص باشد. به‌عنوان مثال پیامبر اکرم. زیرگروه وسیله نقلیه، دربرگیرنده سؤالی است که پاسخ آن، یک وسیلهٔ نقلیه باشد. به‌عنوان مثال کشتی. زیرگروه غیره، شامل هرسؤالی است که در مورد موجودیت باشد؛ ولی در هیچ یک از طبقه‌های فوق جای نگیرد.

گروه زمانی، حاوی سؤالاتی است که پاسخ آن‌ها، در مورد زمان است. این گروه از سؤالات، به سه زیرگروه اسمی، تاریخ و دوره تقسیم می‌شوند. زیرگروه اسمی، سؤالاتی هستند که پاسخ آن‌ها، یک اسم زمانی است. به‌عنوان مثال نام ماه یا نام اعیاد. برای مثال "مسلمانان در چه ماهی روزه می‌گیرند؟ ماه رمضان" زیرگروه تاریخی، سؤالاتی را شامل می‌شود که پاسخ آن‌ها، یک تاریخ است. زیرگروه دوره، سؤالاتی هستند که پاسخ آن‌ها، یک دوره است. به‌عنوان مثال پاسخ آن چند روز، چند ماه و یا امثال آن است.

گروه مکانی شامل سؤالاتی است که پاسخ آن‌ها، یک مکان باشد. به‌عنوان مثال نام مسجد. با توجه به اینکه احتمال می‌رود تعداد این سؤالات در رساله کم باشد، زیرگروهی برای آن در نظر گرفته نشده است. برای مثال "در چه اماکنی، مسافر می‌تواند نماز را کامل بخواند؟ مسجدالحرام، مسجدالنبی و مسجد کوفه."

گروه عددی، شامل سؤالاتی است که پاسخ آن‌ها، یک عدد است که به پنج زیرگروه تعداد، فاصله، پول، نسبت و غیره تقسیم می‌شوند. زیرگروه تعداد، شامل سؤالاتی است که پاسخ آن‌ها، تعداد را نشان می‌دهد. برای مثال "نماز آیات، چند رکعت دارد؟ دو رکعت." زیرگروه فاصله، شامل سؤالاتی است که پاسخ آن‌ها، فاصله باشد. برای مثال "کسی که شغل او مسافرت نباشد، باید قصد چند فرسخ بنماید تا نماز شکسته بخواند؟ هشت فرسخ." زیرگروه پول، دربرگیرنده سؤالاتی است که پاسخ آن‌ها، مقدار پولی باشد. برای مثال "زکات فطره به چه مقدار است؟". زیرگروه نسبت، حاوی سؤالاتی است که پاسخ آن‌ها، بیان‌کننده نسبت باشد. به‌عنوان مثال خمس و ثلث. زیرگروه غیره، شامل سایر مقادیر عددی است که در هیچ یک از طبقه‌های بالا جای نگرفته است.

گروه اسمی، حاوی سؤالاتی است که پاسخ آن‌ها، در مورد یک اسم خاص است. به‌عنوان مثال اسامی غسل‌ها و یا هر اسم دیگری که در هیچ یک از گروه‌های دیگر، قرار نگرفته است. برای مثال "هرگاه به قسمت جدا شده از بدن انسانی که دارای استخوان است، دست بزنیم، چه باید بکنیم؟ باید غسل مس میت انجام شود."

۳-۵- اجزای پیکرهٔ پیشنهادی

همان‌طور که پیشتر اشاره شد، اسناد موجود در پیکره در

قالب فایل‌های XML ذخیره شده‌اند. در این بخش مهم‌ترین اجزای این فایل‌ها با جزییات بیشتری معرفی می‌شوند.

۱-۳-۵- فایل XML سؤال‌های غیرحقیقت استفتائات آیت‌الله العظمی خامنه‌ای

این فایل، حاوی ۲۱۱۸ سؤال غیرحقیقت است. ساختار پیشنهادی این فایل به همراه یک مثال، در شکل (۲) نشان داده شده است.

عنصر TREATISE، تمامی سؤالات موجود در استفتائات آیت‌الله العظمی خامنه‌ای را در برمی‌گیرد. عنصر Question، کلیه اطلاعات مربوط به یک سؤال و پاسخ آن را شامل می‌شود. عنصر QuestionID، شماره سؤال را نگهداری می‌کند که این عنصر منحصربه‌فرد است و برای تمایز میان سؤالات پیکره در نظرگرفته شده است. در عنصر QuestionTitle، عنوان و دسته‌کلی سؤال و در عنصر QuestionSubTitle، زیرعنوان مربوط به سؤال ذخیره می‌شود. نگهداری عنوان و زیرعنوان سؤال، به‌منظور یافتن پاسخ مناسب در سامانه‌های پرسش و پاسخ، می‌تواند مورد استفاده قرار گیرد. برای مثال درصورتی‌که عنوان سؤال، تقلید تشخیص داده شود، بازهٔ استخراج پاسخ را به فصل تقلید از کتاب رساله آیت‌الله العظمی مکارم محدود می‌توان کرد. تشخیص مناسب عنوان و زیرعنوان سؤال، منجر به بهبود عملکرد مؤلفه استخراج پاسخ می‌شود.

در عنصر QuestionContent، متن سؤال ذخیره و درعنصر QuestionType، نوع سؤال مدنظر نگهداری می‌شود. انواع سؤالات در بخش ۳-۲ به طور کامل معرفی شده‌که در تهیه پیکره، برای عنصر نوع سؤال، تنها مقدار حقیقت و غیرحقیقت نگهداری شده و از نگهداری دسته‌های ریزتر، اجتناب شده است. در آینده، دسته‌بندی ریزتر انواع سؤالات را به پیکره می‌توان اضافه کرد.

DifficultFromQuestioner میزان سختی سؤال را از نظر پرسشگر و Difficult_FromResponder میزان سختی سؤال را از نظر پاسخ‌دهنده نشان می‌دهند که حاوی مقادیر آسان، متوسط و سخت می‌تواند باشد. این اطلاعات به‌منظور ارزیابی عملکرد سامانه ذخیره می‌شود. طراح سامانهٔ پرسش و پاسخ می‌تواند بدین وسیله ارزیابی‌کندکه سامانهٔ طراحی‌شده به چه نوع سؤالاتی از نظر سختی، پاسخ مناسب داده است. به‌طورکلی سؤالات حقیقت در یکی از دو دسته آسان و متوسط جای می‌گیرند و سؤالات غیرحقیقت در یکی از دو دسته متوسط و سخت قرار می‌گیرند.

```
<TREATISE>
  <Question>
    <QuestionID>1</QuestionID>
    <QuestionTitle>
      احکام تقلید
    </QuestionTitle>
    <QuestionSubtitle>
      راههای سه گانه:احتیاط،اجتهاد،تقلید
    </QuestionSubtitle>
    <QuestionContent>
      آیا تقلید ادلهء شرعی دارد؟
    </QuestionContent>
    <QuestionType>
      غیرحقیقت
    </QuestionType>
    <Answer>
      <AnswerContent>
        تقلید،ادلهء شرعی دارد و عقل نیز حکم میکند
        که شخص ناآگاه بهاحکام دین باید به مجتهد
        جامع الشرائط مراجعه کند .
      </AnswerContent>
      <CourceGrainedCategory>
        توصیفی
      </CourceGrainedCategory>
      <FineGrainedCategory>
        توصیفی
      </FineGrainedCategory>
    </Answer>
    <DifficultFromQuestioner>
      متوسط
    </DifficultFromQuestioner>
    <DifficultFromResponder>
      متوسط
    </DifficultFromResponder>
  </Question>
</TREATISE>
```

(شکل-۲): فایل XML سؤالات غیرحقیقت

(Figure-2): XML file of non-factoid questions

عنصر Answer، اطلاعات مربوط به پاسخ را به‌طور کامل نگهداری می‌کند. در عنصر AnswerContent، متن پاسخ مربوطه قرار خواهدگرفت. CourseGrainedCategory، نوع پاسخ مورد انتظار را در سطح درشت‌دانه و FineGrainedCategory، نوع پاسخ مورد انتظار را در سطح ریزدانه، طبق جدول (۲) نگهداری می‌کنند.

۲-۳-۵- فایل XML سؤالات حقیقت استفتائات آیت‌الله العظمی خامنه‌ای

علاوه‌بر سؤالات غیرحقیقت که در بخش ۱-۷ توضیح داده شد، پیکره پیشنهادی، ۲،۰۵۱ سؤال حقیقت از ا ستفتائات آیت‌الله العظمی خامنه‌ای را نیز شامل می‌شود. ساختار این فایل به همراه یک مثال، در شکل (۳) نشان داده شده است.

```
<?xml version="1.0" encoding="utf-8"?
<FactoidQuestionsCorpus>
  <FactoidQuestion>
    <FactoidQuestionId ParentId="1">
      1
    </FactoidQuestionId>
    <FactoidQuestionContent>
      آیا تقلید، ادلهء شرعی دارد؟
    </FactoidQuestionContent>
    <Answer>
      <FactoidAnswerContent>
        بله
      </FactoidAnswerContent>
      <CourseGrainedCategory>
        تایید ی
      </CourseGrainedCategory>
      <FineGrainedCategory>
        بله
      </FineGrainedCategory>
    </Answer>
    <DifficultFromQuestioner>
      آسان
    </DifficultFromQuestioner>
    <DificultFromResponder>
      آسان
    </DificultFromResponder>
  </FactoidQuestion>
</FactoidQuestionsCorpus>
```

(شکل-۳): فایل XML سؤالات حقیقت
(Figure-3): XML file of factoid questions

این سؤالات حقیقت، که برگرفته از سؤالات غیر حقیقت بخش ۷-۱ هستند، توسط اعضای تیم، با استفاده از نرم‌افزاری که در بخش ۸ معرفی خواهد شد، ایجاد شده است. هدف ایجاد مجموعه سؤالات حقیقت، این است که پیکره تهیه شده، پیکره جامعی باشد و بتواند در طراحی سامانه‌های پرسش و پاسخ حقیقت و غیرحقیقت به‌کار گرفته شود.

عنصر FactoidQuestionsCorpus، تمامی سؤالات حقیقت موجود را شامل می‌شود. عنصر FactoidQuestion، اطلاعات مربوط به یک سؤال حقیقت را نگهداری می‌کند. عنصر FactoidQuestionId، یک شناسه منحصر به فرد را برای هر سؤال حقیقت، ذخیره می‌کند. این عنصر دارای ویژگی parentId است که این ویژگی برابر با شماره سؤال (QuestionID) مربوطه از پیکره سؤالات غیرحقیقت است که این سؤال حقیقت از آن ناشی شده است. لازم به ذکر است که برای هر سؤال غیرحقیقت، بیش از یک سؤال حقیقت می‌تواند ذخیره شود.

در عنصر FactoidQuestionContent، متن سؤال حقیقت مدنظر نگهداری می شود. FactoidAnswerContent، متن پاسخ حقیقت مربوطه را ذخیره می‌کند. سایر عناصر پیش‌تر معرفی شده‌اند.

۴-۵- فایل XML رساله آیت‌الله العظمی مکارم شیرازی

این فایل، شامل ۲،۴۵۶ مسأله از کتاب رساله آیت‌الله العظمی مکارم شیرازی است. ساختار این فایل به همراه یک مثال، در شکل (۴) نشان داده شده است.

```
<?xml version="1.0" encoding="utf-8"?>
<MakaremCorpus>
  <Problem>
    <ProblemID>
      1
    </ProblemID>
    <ProblemTitle>
      تقلید
    </ProblemTitle>
    <ProblemSubTitle>
      احکام تقلید
    </ProblemSubTitle>
    <ProblemContent>
      هیچ مسلمانی نمی‌تواند در اصول دین تقلید نماید،
      بلکه باید آنها را به فراخور حال خویش بداند
      ولی در فروع دین یعنی احکام ودستورات عملی،
      اگر مجتهد باشد به عقیدهء خود عمل می‌کند
      و اگر مجتهد نباشد باید از مجتهدی تقلید کند.
    </ProblemContent>
    <PageNumber>
      19
    </PageNumber>
  </Problem>
</MakaremCorpus>
```

(شکل-۴): فایل XML آیت‌الله مکارم شیرازی
(Figure-4): XML file of Ayatollah Makarem shirazi

عنصر MakaremCorpus، تمامی مسأله‌های رساله آیت‌الله العظمی مکارم را دربرمی‌گیرد. عنصر Problem، اطلاعات مربوط به یک مسأله را به‌طورکامل نگهداری می‌کند. ProblemID، شمارهٔ مسأله مربوط به رساله است که به‌عنوان شماره پاراگراف نیز می‌تواند به کار رود که این شماره منحصر به فرد است و برای تمایز میان مسأله‌های رساله آیت‌الله العظمی مکارم، درنظر گرفته شده است.

ProblemTitle، عنوان و دسته کلی مسأله استخراج شده و ProblemSubTitle، زیرعنوان یا زیرعنوان‌های مربوط به‌یک مسأله را نگهداری می‌کنند. یکی از دلایل نگهداری عنوان و زیرعنوان برای استفتائات آیت‌الله العظمی خامنه‌ای و رساله آیت‌الله العظمی مکارم، این است که درصورت تشخیص مناسب عنوان و زیرعنوان یک سؤال، بتوان بازهٔ تشخیص پاسخ را در رساله، محدودتر کرد. ProblemContent،

محتـوای متـن یـک مسألـه را شـامـل می‌شـود. درعنصـر PageNumber، شماره صفحه مسأله از پیکره آیت‌الله العظمی مکارم ذخیره می‌شود. یکی از دلایل نگهداری شماره صفحه و پاراگراف، این است که مؤلفه بازیابی اطلاعات بتواند عملیات بازیابی را بـر اساس شماره صفحـه و یـا شماره پاراگراف انجام دهـد. به‌عنوان مـثال مؤلفه بـازیابی اطلاعات، پـاراگراف‌های مرتبط با یک سؤال را بازیابی کند. بدین صورت مؤلفه بازیابی اطلاعات در چند سطح بازیابی صفحه، پاراگراف و پاسخ دقیق، می‌تواند اعمال شود.

۱-۴-۵- فایل XML ارتباط سؤالات استفتائات آیت‌الله العظمـی خامنه‌ای و مـسائل رسـاله آیـت‌الله العظمی مکارم

در این فایل، ارتباط میان سـؤالات موجود در اسـتفتائات آیـت‌الله العظمی خـامـنه‌ای و مسـأله های موجود در پیکرهٔ آیت‌الله العظمی مکارم، نگهداری می‌شود. ساختار این فایل به همراه یک مثال در شکل (۵) نشان داده شده است.

```
<?xml version="1.0" encoding="utf-8"?>
<MakaremCorpus>
  <Problem>
    <ProblemNumber>
      2
    </ProblemNumber>
    <Keys>
      <Question>
        <Key QuestionNumber="1">
          2
        </Key>
        <DifficultFromQuestioner>
          آسان
        </DifficultFromQuestioner>
        <DifficultFromResponder>
          آسان
        </DifficultFromResponder>
      </Question>
    </Keys>
  </Problem>
</MakaremCorpus>
```

(شکل-۵): فایل xml روابط بین سؤالات و پاسخ ها
(Figure-5): XML file of relation beetwen questions and answers

عنصر MakaremCorpus، شامل تمامی مسأله‌هایی از رسالـهٔ آیت‌الله العظمی مکارم اسـت‌کـه با سـؤالات موجود در اسـتفتائات آیت‌الله العظمی خامنه‌ای، ارتباط دارند. عنصـر Problem، حاوی اطلاعات مسأله‌ای است که دست‌کم با یکی از سـؤالات اسـتفتائات آیت‌الله العظمی خامنه‌ای ارتباط دارد. ProblemNumber، شـماره مربوط به مسـأله اسـت. عنصـر Keys دربردارنده اطلاعات مربوط به سـؤالات مرتبط با این مسـأله اسـت. هر سـؤال مرتبط با این مسـأله در عنصـر Question، ذخیره مـی‌شود. عنـصر Key، میزان ارتباط سـؤال با مسـأله را نشـان می‌دهد. این عنصـر، دو مقدار ۱ یا ۲ را می‌تواند شامل شود.

مـقدار ۲، نشـان‌دهـندهٔ ارتـباط کـامـل و مـقدار۱ نشـان‌دهنده ارتباط جزئی مسـأله با سـؤال اسـت. نگهداری ارتباط مسـأله با سـؤال در دو سـطح، در ارزیابی سـامانه‌های پرسش و پاسخ، موثر خواهد بود تا بتوان ارزیابی مناسب‌تری از عملکرد سامانه داشت.

مثلا اگر سیـسـتم ۱ نـتواند پاسـخی با درجه‌ی ارتباط ۲ را بازیابی کند، اما قادر باشـد پاسـخ‌هایی با درجه‌ی ارتباط ۱ را بازیابی‌کـند، در مقابل سـیسـتم ۲ که نتواند پاسـخی با درجه ارتـباط ۱یـا ۲ را بازیابی کـند، عملکرد بهتری خواهد داشت. ویژگی QuestionNumber، نشان‌دهنده شماره سؤال مرتبط با این مساله است. سایر عناصر پیش‌تر معرفی شده‌اند.

۶- ابزار نشـانـه‌گـذاری و وضـعـیـت در دسترس بودن پیکره

جهت انجام فرآیند نشانه‌گذاری اسناد XML، یک نرم‌افزار به نام ابزار نشـانه‌گذاری پرسـش و پاسـخ رسـاله[1]، توسـعه داده شده است‌کـه بخشی از ویژگی‌های این نرم‌افزار در شکل (۶) نـشان داده شـده‌اسـت. با اسـتفاده از این نرم‌افزار، به راحتی می‌توان برچسـب‌های مربوط بـه پیکره را مشـاهده، بـه روزرسـانی و حـذف کرد. همچنین امکان ایجاد سـؤالات حقیقت، ارتباط سـؤال های اسـتفتائات آیـت‌الله العظمی خامنه‌ای و مسائل آیـت‌الله العظمی مکارم شیرازی نیز در این نرم‌افزار فراهم شده است تا کلیه برچسب‌های معرفی‌شده در بخش قبل، به‌راحتی توسط افراد متخصص اعمال شود.

نشـانه‌گذاری یک پیکره بدون اسـتفاده از نرم‌افزار، بسیار د شوار است. استفاده از نرم‌افزار به‌منظور نشانه‌گذاری اسناد موجب افزایش سرعت و دقت در تهیه پیکره مـی‌شود. جهت انجام فرآیند نشانه‌گذاری اسناد XML، یک نرم‌افزار به نام ابزار نشـانه‌گذاری پرسـش و پاسـخ مذهبی[2] به زبان C# توسعه داده شده است که رابط گرفیکی این نرم‌افزار در شکل (۶) نـشان داده شـده ا ست. مهم‌ترین ویژگی‌های این نرم‌افزار عبارتند از:

[1] Treatise QA Annotation Tool (TQAAT)
[2] Religious QA Annotation Tool (RQAAT)

۶-۱- افزایش خوانایی

این نرم‌افزار فایل خام اولیه سؤال و جواب را در قالب متن دریافت می‌کند. از آن جایی‌که پردازش فایل متنی کار دشواری است، این نرم‌افزار فایل خام اولیه را به شکل xml تبدیل می کند. ساختار فایل xml ذخیره شده در این سامانه در بخش قبل به‌طورکامل شرح داده شده است. تبدیل فایل متنی به XML امکان خوانایی و توسعه‌پذیری پیکره را افزایش می‌دهد.

۶-۲- فرم مربوط به سؤالات غیرحقیقت

به‌منظور نشانه‌گذاری اسناد غیرحقیقت، فرمی طراحی شده است که بتوان به‌سرعت برچسب‌های مناسب را به پیکره اضافه کرد. کاربر برای هر سؤال غیرحقیقت، نوع سؤال، دسته‌بندی معنایی پاسخ در سطح درشت‌دانه، دسته‌بندی معنایی پاسخ در سطح ریزدانه، سختی سؤال از نظر پرسش‌گر و سختی سؤال از نظر پاسخ‌دهنده را می‌تواند نشانه‌گذاری کند. به‌منظور سهولت فرآیند نشانه‌گذاری، این عناصر به‌صورت فهرست بازشو در نظر گرفته شده‌اند تا کاربر بتواند مقدار مورد نظر خود را از فهرست انتخاب کند.

۶-۳- فرم مربوط به سؤالات حقیقت

در نرم‌افزار پیشنهادی این امکان فراهم شده است که کاربر بتواند برای هر سؤال غیرحقیقت، سؤالات حقیقت مناسب را استخراج کند. برای این منظور، در فرم مربوط به سؤالات غیر حقیقت، برای هر سؤال غیرحقیقت وارد فرم مربوط به اطلاعات حقیقت می‌توان شد. در این فرم فهرست سؤالات حقیقت مربوط به سؤال مدنظر نشان داده می‌شود و کاربر سؤالی را به مجموعه سؤال حقیقت اضافه و یا از مجموعه می‌تواند حذف کند. همچنین امکان ویرایش سؤالات حقیقت ذخیره‌شده نیز فراهم شده است. برای هر سؤال حقیقت، کاربر متن سؤال حقیقت و متن پاسخ حقیقت را می‌تواند وارد کند. همچنین امکان نشانه‌گذاری دسته‌بندی معنایی پاسخ در سطح درشت‌دانه، دسته‌بندی معنایی پاسخ در سطح ریزدانه، سختی سؤال از نظر پرسشگر و سختی سؤال از نظر پاسخ‌دهنده فراهم شده است. به‌طور مشابه به‌منظور سهولت فرآیند نشانه‌گذاری، این عناصر به صورت فهرست باز شو در نظر گرفته شده‌اند.

۶-۴- مستقل‌بودن از زبان

به‌منظور ساخت اسناد XML، از xml schema استفاده شده است. استفاده از xml schema امکان تغییر اسناد xml را به‌صورت پویا فراهم می‌کند. با اعمال تغییرات بر روی Xml schema، تغییرت مدنظر بر روی فایل xml ایجاد می‌شود و توسعه‌پذیری برنامه افزایش می‌یابد. همچنین این امر موجب می‌شود که برنامه مستقل از زبان باشد و با اعمال تغییرات کوچک در ساختار xml scheam، ابزار طراحی‌شده بتواند در سایر زبان‌ها نیز به کار گرفته شود. همچنین این امکان فراهم شده است که طراحی فرم به‌صورت پویا باشد، به‌طوری‌که با تغییر ویژگی‌های xml schema، تغییرات مدنظر به‌صورت پویا بر روی فرم ایجاد شود. برای مثال با افزودن یک ویژگی به ساختار xml schema مربوط به سؤالات غیر حقیقت، این ویژگی به‌صورت پویا به فرم سؤالات غیرحقیقت اضافه می‌شود.

۶-۵- فرم جستجو

از دیگر ویژگی‌های این نرم‌افزار به امکان جستجو و گزارش‌گیری نیز می‌توان اشاره کرد. فرمی به‌منظور جستجو طراحی شده است که کاربر بتواند سؤالات را بر اساس نوع سؤال، سختی سؤال، عنوان سؤال و دسته معنایی پاسخ جستجو کند. برای مثال کاربر فهرست سؤالات حقیقت مربوط به فصل نماز را که در پیکره ذخیره شده است، می‌تواند مشاهده کند.

این نرم‌افزار خاص دامنه مذهبی نیست و به‌راحتی قابل توسعه است و می‌تواند به‌منظور نشانه‌گذاری کلیهٔ سامانه‌های پرسش و پاسخ مورد استفاده قرار گیرد. اگر چه ابزار نشانه‌گذاری پرسش و پاسخ مذهبی به‌منظور نشانه‌گذاری اسناد فارسی ارایه شده ولی مستقل از زبان است و به‌راحتی در سایر زبان‌ها می‌تواند به کار گرفته شود.

نخستین نسخه پیکره شامل ۲،۱۱۸ سؤال غیرحقیقت و ۲،۰۵۰ سؤال حقیقت، از طریق نشانی گروه پردازش زبان طبیعی دانشگاه گیلان http://nlp.guilan.ac.ir/ به‌صورت رایگان در دسترس عموم قرار دارد.

۷- ارائهٔ سامانهٔ پرسش و پاسخ

به‌منظور ارزیابی صحت عملکرد پیکره پیشنهادی، لازم است یک سامانهٔ پرسش و پاسخ معرفی شود. سامانهٔ پیشنهادی از دو مؤلفه پیش‌پردازش سؤال و بازیابی سند تشکیل شده است.

۱-۷- پیش‌پردازش سؤال

در این بخش ابتدا متن ورودی نرمال[1]و تمیز می‌شود. یکی از مهم‌ترین اقداماتی که در نرمال‌سازی انجام می‌شود، اصلاح نیم‌فاصله‌های متن است. برای مثال کلماتی مانند "می شود" و "آن‌ها"، به‌ترتیب به شکل "می‌شود" و "آن‌ها" تبدیل[2] می‌شوند. بعد از اعمال نرمال‌سازی، عمل جداسازی جملات بر روی متن نرمال‌شده، انجام می‌گیرد تا متن نرمال‌شده به تعدادی جمله تبدیل شود؛ سپس بر روی هر یک از جملات، جداسازی کلمات[3] انجام می‌شود. یکی دیگر از پیش‌پردازش‌هایی که در این مرحله انجام شده، ریشه‌یابی است تا هر کلمه به شکل اصلی و ریشه آن تبدیل شود به‌عنوان مثال کلمه "کتاب‌ها" به "کتاب" تبدیل می‌شود.

به‌منظور اعمال این پیش‌پردازش‌ها در زبان فارسی، از ابزار هضم استفاده شده است.[4] از ویژگی‌های این برنامه به قابلیت تمیز و مرتب‌کردن متن، تقطیع جمله‌ها و واژه‌ها، ریشه‌یابی واژه‌ها، تحلیل صرفی و تجزیهٔ نحوی جمله می‌توان اشاره کرد.

یکی دیگر از اقداماتی که در این بخش انجام شده، حذف کلمات توقف است. در زبان فارسی فهرستی حاوی ۳۳۲ کلمه توقف ارایه شده[5] که در این پژوهش از این مجموعه کلمات توقف استفاده شده است.

سؤال ورودی پس از اعمال پیش‌پردازش‌های بیان‌شده، به‌عنوان پرس‌وجوی بازیابی اطلاعات در اختیار مؤلفه بازیابی سند قرار می‌گیرد. لازم به ذکر است که کلیه پیش‌پردازش‌های انجام‌شده بر روی سؤال، به‌طور مشابه بر روی مجموعه پاسخ‌ها نیز اعمال می‌شود و مجموعه پاسخ‌ها پس از اعمال پیش‌پردازش‌های بیان شده در اختیار مؤلفه بازیابی سند قرار می‌گیرد.

۲-۷- بازیابی سند

این مؤلفه، پرس‌وجوی تولیدشده از مؤلفه پردازش سؤال را دریافت کرده، سپس مشابه‌ترین اسناد موجود با این پرس‌وجو را از میان مجموعه پاسخ‌ها بازیابی می‌کند. به‌منظور بازیابی اسناد، به‌طورعمومی از موتورهای جستجوی منبع باز استفاده می‌شود که به‌تازگی استفاده از موتورهای جستجوی بولین در سامانه‌های پرسش و پا سخ مورد توجه پژوهش‌گران قرار گرفته است. یکی از معروف‌ترین موتورهای جستجوی بولین، موتور جستجوی لوسین[6] است که به‌رایگان در دسترس عموم قرار دارد.[7] این موتور جستجو بر اساس پرس‌وجوی بولین عمل می‌کند و بر پایه مدل فضای بردار TF. IDF[8] است.

نحوه عملکرد این موتورهای جستجو به‌این‌صورت است که ابتدا مجموعه پاسخ‌ها را نمایه‌گذاری می‌کنند، سپس یک سؤال را به‌عنوان ورودی دریافت کرده و با استفاده از مدل و فرمول بازیابی خود، به هر یک از اسناد با توجه به میزان شباهتشان با سؤال، یک نمره نسبت می‌دهند؛ سپس اسناد را بر اساس نمره به ترتیب نزولی مرتب می‌کنند تا بهترین سند در رتبه یک قرار گیرد.

۳-۷- ارزیابی سامانهٔ پیشنهادی

به‌منظور ارزیابی سامانه‌های پرسش و پاسخ، استفاده از دو معیار دقت[9] و میانگین معکوس رتبه[10] (MRR)، متداول است. معیار دقت، درصد سؤالاتی را نشان می‌دهد که در میان n پاسخ برگردانده‌شده، دست‌کم دارای یک پاسخ درست هستند.

معیار MRR برای رتبه‌بندی سامانه‌هایی مناسب است که چندین پاسخ را برای یک سؤال برمی‌گردانند. فرض کنید Q یک مجموعه سؤال و r_i رتبه نخستین پاسخ درست برای سؤال i است که اگر هیچ پاسخ درستی برگردانده نشود، مقدارش برابر با صفر خواهد بود. این معیار طبق رابطه (۱) محاسبه می‌شود[8].

$$MRR = \frac{\sum_{i=0}^{|Q|} \frac{1}{r_i}}{|Q|} \qquad (۱)$$

آزمایش‌های انجام‌شده بر روی سامانهٔ معرفی‌شده نشان می‌دهد که سامانهٔ پیشنهادی توانسته است به دقت ۸۲/۲۹ و MRR برابر با ۵۶/۷۳ درصد دست یابد. ازآنجاکه تاکنون در زبان فارسی سامانهٔ پرسش و پاسخی ارائه نشده و این سامانه نخستین سامانهٔ پرسش و پاسخ در زبان فارسی است، درنتیجه امکان مقایسه سامانهٔ پیشنهادی با سایر سامانه‌ها میسر نیست.

[1] Normalize
[2] Sentence Tokenizer
[3] Word Tokenizer
[4] https://github.com/mojtaba-khallash/JHazm
[5] http://members.unine.ch/jacques.savoy/clef/index.html
[6] lucence
[7] https://lucene.apache.org/.
[8] term frequency–inverse document frequency
[9] accuracy
[10] mean reciprocal rank

۸- نتیجه‌گیری

در این مقاله، مراحل کامل توسعه یک پیکرهٔ متنی پرسش و پاسخ به زبان فارسی به‌طورکامل مطرح شد. منابع داده‌ای اولیه، نحوهٔ توسعه آن و همچنین ساختار فایل‌های پیکره به‌طور کامل شرح داده شد. با توجه به ویژگی‌های ذکرشده، پیکره *رسائل و مسائل* حاوی ۲،۱۱۸ سؤال غیرحقیقت و ۲،۰۵۱ سؤال حقیقت، نخستین پیکره در زبان فارسی است که برای کلیه مراحل سامانه‌های پرسش و پاسخ می‌تواند مورداستفاده قرار گیرد. لازم به ذکر است که هیچ یک از پیکره‌های انگلیسی مطرح شده، به‌تنهایی برای کلیه مؤلفه‌های سامانه‌های پرسش و پاسخ نمی‌توانند مورد استفاده قرار گیرند؛ همچنین پیکره‌ای در زبان انگلیسی وجود ندارد که بتواند همزمان برای داده‌های حقیقت و غیرحقیقت مورد استفاده قرار گیرد؛ درحالی‌که پیکره پیشنهادی به گونه‌ای طراحی شده است که بتواند برای انواع سؤالات حقیقت و غیرحقیقت مورد استفاده قرار گیرد؛ ازاین‌رو، پیکره پیشنهادی قابل قیاس با پیکره‌های انگلیسی مطرح شده است.

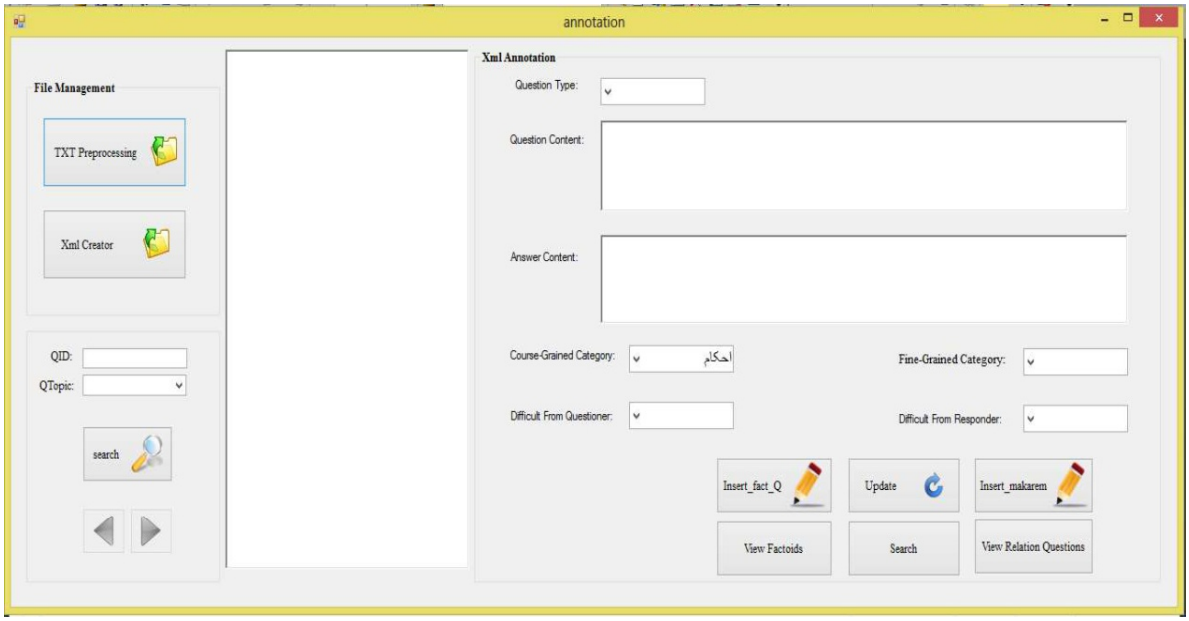

(شکل-۶): ابزار نشانه‌گذاری پرسش و پاسخ رساله
(Figure-6): Treatise Question Answering Annotation Tool

در ادامه یک سامانهٔ پرسش و پاسخ بر روی پیکره پیشنهادی معرفی شد که این سامانه توانست به دقت ۸۲/۲۹ و MRR برابر با ۵۶/۷۳ درصد دست یابد.

به‌عنوان فعالیت‌های آینده، با استفاده از روش‌های پرکاربرد یادگیری ماشین و بازیابی اطلاعات، سامانهٔ پرسش و پاسخ معرفی‌شده را می‌توان بهبود و دامنه اطلاعات موجود در این پیکره را افزایش داد، به گونه‌ای که این پیکره، حاوی اسناد رساله تعداد مراجع تقلید بیشتری باشد. انواع سؤالات پیکره را طبق تعریف ۳-۲ در سطح ریزتر می‌توان ذخیره کرد. همچنین با استفاده از سؤال و جواب‌های موجود در سایت‌های مذهبی، تعداد سؤالات این پیکره را می‌توان گسترش داد.

سپاس‌گزاری

از مرجع تحقیقات علوم اسلامی(نور)، که منبع داده خام رساله آیت‌الله العظمی مکارم و استفتائات آیت‌الله العظمی خامنه‌ای را در را ستای این پژوهش در اختیارمان قرار دادند، سپاس‌گزاریم.

۹- مراجع 9- References

[۱] حسینی، پدرام و همکاران، "پیکرهٔ فارسی تحلیل احساس سِنتی‌پِرس: توسعهٔ یک پیکرهٔ تحلیل احساس متنی برای زبان فارسی". *سومین کنفرانس زبانشناسی رایانشی*, ۱۳۹۳.

[1] (Hosseini, P. et al., "Persian Sentiment Analysis Corpus: Developing a textual sentiment corpus for Persia". *Third conference on Computational Linguistics*, Sharif University of Technology, 2014.)

[۲] قائمی، هادی، کاهانی، محسن. "دسته‌بندی پرسش‌ها با استفاده از ترکیب دسته‌بندها". *پردازش علائم و داده‌ها*. ۱۳۹۵; ۱۳ (۳): ۱۱۲-۹۹

[2] (Ghaemi, .H, kahani, .M. “Question Classification using nsemble Classifiers “, *JSDP* , 13 (3), 2016, 99-112)

[3] AleAhmad, A. et al., “Hamshahri: A standard Persian text collection”, *Knowledge-Based Systems*, 22(5), 2009, pp.382–387.

[4] Bijankhan, M. et al., “Lessons from building a Persian written corpus: Peykare”. *Language Resources and Evaluation,* 45(2), 2010, pp.143–164.

[5] Greenwood, M.A., “Open-domain question answering”, *Foundations and Trends in Information Retrieval*, 2005.

[6] Gupta, P. and Gupta, V.,“A survey of text question answering techniques”, *International Journal of Computer Applications*, 53(4), 2012, pp.1–8.

[7] Hirschman, L. and Gaizauskas, R., “Natural language question answering: the view from here”, *Natural Language Engineering*, 7(04), 2000, pp.275–300.

[8] Kolomiyets, O. and Moens, M.-F., “A survey on question answering technology from an information retrieval perspective*”, Information Sciences*, 181(24), 2011, pp.5412–5434.

[9] Lee, G. et al., “SiteQ: Engineering High Performance QA System Using”, *Lexico-Semantic Pattern Matching and Shallow NLP. In TREC*, 2001.

[10] Li, X. and Roth, D., “Learning question classifiers”, *In Proceedings of the 19th international conference on Computational linguistics*., 2002.

[11] Li, X. and Roth, D., “Learning question classifiers: the role of semantic information”, *Natural Language Engineering*, 12(03), 2006, pp.229–249.

[12] Magnini, B. et al., “Creating the DISEQuA corpus: a test set for multilingual question answering”, *In Comparative Evaluation of Multilingual Information Access Systems*, 2004, pp. 487–500.

[13] Manning, C.D., Raghavan, P. and Schütze, H., “Introduction to information retrieval”, *Cambridge university press Cambridge* , 2008.

[14] Moghaddas, B.B. et al, “Pasokh: A standard corpus for the evaluation of Persian text summarizers”. *In Computer and Knowledge Engineering (ICCKE)*, 2013, pp. 471–475.

[15] Moll, D. and Vicedo, L., “Question Answering in Restricted Domains : An Overview”, *Computational Linguistics* , 2007.

[16] Mollaei, A., Rahati-Quchani, S. and Estaji, A., “Question classification in Persian language based on conditional random fields”, *2nd International eConference on Computer and Knowledge Engineering (ICCKE),* 2012, pp.295–300.

[17] Rasooli, M.S et al., “Development of a Persian syntactic dependency treebank”. *In Proceedings of the 2013 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2013, pp. 306–314.

[18] Smith, N.A., Heilman, M. and Hwa, R., “Question generation as a competitive undergraduate course project*”, In Proceedings of the NSF Workshop on the Question Generation Shared Task and Evaluation Challenge*, 2008, pp. 4–6.

[19] Tellex, S. et al., “Quantitative evaluation of passage retrieval algorithms for question answering”, *In Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval*, 2003, pp. 41–47.

[20] Tom, D. et al., “TrainQA: a Training Corpus for Corpus-Based Question Answering Systems”, *In Proc. 8th Int. Conf. on Computational Linguistics and Intelligent Text Processing*, 2007, pp. 1–7.

[21] Voorhees, E.M., “Building a question answering test collection”*, ACM SIGIR*, 2000.

[22] Voorhees, E.M., “The TREC-8 Question Answering Track Report”, *In TREC*, 1999, pp. 77–82.

[23]Yaghoobzadeh, Y. et al., “ISO-TimeML Event Extraction in Persian Text”,*COLING*, 2012, pp.2931-2944.

[24]Zhang, D. and Lee, W.S., “Question classification using support vector machines”, *In Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval*, 2003, pp. 26–32.

یاسمن برشبان، مدرک کارشناسی خود را در رشته مهندسی کامپیوتر گرایش نرمافزار در سال ۱۳۹۲ از دانشگاه تربیت دبیر شهید رجایی تهران اخذ کرد. وی تحصیلات خود را در مقطع کارشناسی ارشد همان رشته در سال ۱۳۹۴ در دانشگاه گیلان به پایان رساند. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: پردازش

زبان طبیعی، بازیابی اطلاعات و یادگیری ماشین.
نشانی رایانامه ایشان عبارت است از:

boreshban@msc.guilan.ac.ir

حامد یوسفی‌نسب، مدرک کارشناسی خود را در رشته مهندسی کامپیوتر گرایش نرم‌افزار در سال ۱۳۹۴ از دانشگاه گیلان اخذ کرد. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: بازیابی اطلاعات و پردازش زبان طبیعی.
نشانی رایانامه ایشان عبارت است از:

hdyousefi@gmail.com

سید ابوالقاسم میرروشندل، مدرک کارشناسی خود را در رشته مهندسی کامپیوتر در سال ۱۳۸۴ از دانشگاه تهران و مدرک کارشناسی ارشد و دکترای خود را در همان رشته بهترتیب در سال‌های ۱۳۸۶ و ۱۳۹۱ از دانشگاه صنعتی شریف تهران دریافت کرد. ایشان از سال ۱۳۹۱ استادیار گروه مهندسی کامپیوتر دانشگاه گیلان هستند. از ایشان بیش از سی مقالهٔ فنی در نشریات و همایش‌های معتبر به چاپ رسیده است. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: داده‌کاوی، یادگیری ماشین و پردازش زبان طبیعی.
نشانی رایانامه ایشان عبارت است از:

mirroshandel@guilan.ac.ir