



دسته‌بندی پرسش‌ها با استفاده از ترکیب دسته‌بندها

هادی قائمی* و محسن کاهانی

آزمایشگاه فناوری وب معنایی دانشگاه فردوسی مشهد، مشهد، ایران



چکیده

هدف از تولید و گسترش سامانه‌های پرسش و پاسخ، ایجاد پاسخ دقیق برای پرسش داده شده به زبان طبیعی است. یکی از مهم‌ترین بخش‌های سامانه‌های پرسش و پاسخ، دسته‌بندی پرسش است. عمل دسته‌بندی پرسش، پیش‌بینی نوع پاسخ موردنیاز برای پرسش داده شده به زبان طبیعی است. کارهای انجام شده در این زمینه را می‌توان در دو دسته مبتنی بر قانون و مبتنی بر یادگیری تقسیم کرد. در این مقاله یک معماری جدید برای دسته‌بندی ترکیبی پرسش‌ها ارائه شده است، نتایج هریک از دسته‌بندها توسط پنج روش رأی‌گیری وزن دار، فضای دانش رفتار، بیز ساده، کلیشه تصمیم و دهمپسترشفر ترکیب شده و خروجی نهایی را شکل می‌دهد. این روش ترکیبی متشکل از دو دسته‌بند مبتنی بر یادگیری ماشین (ماشین بردار پشتیبان و نمایش پراکنده) و یک دسته‌بند مبتنی بر قانون استفاده شده است. عملیات دسته‌بندی مبتنی بر یادگیری با توجه به مجموعه ویژگی‌های استخراج شده از پرسش‌ها انجام می‌پذیرد. این ویژگی‌ها براساس ساختار لغوی و نحوی پرسش‌ها استخراج شده‌اند. در پایان نتایج حاصل از دسته‌بندها با روش‌های معمول در ترکیب دسته‌بندی تک‌طبقه ترکیب شده‌اند و نتایج حاصل بیان‌کننده بهبود عملیات دسته‌بندی نسبت به روش‌های موجود است.

واژگان کلیدی: دسته‌بندی پرسش‌ها، مبتنی بر قانون، مبتنی بر یادگیری، نمایش پراکنده، ماشین بردار پشتیبان، پرسش و پاسخ.

Question Classification using Ensemble Classifiers

Hadi Ghaemi* & Mohsen Kahani

Web Technology Lab. Ferdowsi University of Mashhad, Mashhad, Iran

Abstract

Question answering systems are produced and developed to provide exact answers to the question posted in natural language. One of the most important parts of question answering systems is question classification. The purpose of question classification is predicting the kind of answer needed for the question in natural language. The literature works can be categorized as rule-based and learning-based methods. This paper proposes a novel architecture for hybrid classification of questions. The results of the classifiers were combined by five methods of Weighted Voting, Behavior Knowledge space, Naive Bayes, Decision Template and Dempster-Shafer. The method uses a combination of two classifiers based on machine learning (Support Vector Machine and Sparse Representation) and one rule-based classifier. The learning-based classification uses the set of features extracted from the questions. The features are extracted on the basis of the lexical and syntactic structure of the questions. The results from the classifiers were combined by the methods that are common in the combination of one-class classifiers and the Obtained results indicate the improvement of the classification operations in comparison with the present methods.

Keywords: Question classification, Rule-based, Learning-based, Sparse Representation, Support Vector Machine, Question answering.

* نویسنده عهده‌دار مکاتبات

سال ۱۳۹۵ شماره ۳ پیاپی ۲۹



۱- مقدمه

به طور کلی برای دسته‌بندی پرسش‌ها سه انگیزه اصلی کاهش فضای جستجو، مشخص کردن پاسخ و انتخاب راهبرد جستجو را می‌توان در نظر گرفت. در ادامه هر یک از دلایل توضیح داده خواهند شد.

[جدول-۱]: دسته‌های پرسش [11]
(Table-1): Question classes [11]

Coarse	Fine
ABBR	اختصار، گسترش
DESC	تعریف، توضیح، چگونگی، دلیل
ENTY	حیوان، انسان، رنگ، موجود زنده، ارز، مربی، رویداد، خوارک، ابزار آلات، زبان، نامه، زمین، کالا، مذهب، ورزش، اجسام، سمبول‌ها، تکنیک، اصطلاح، رسانه، واژه
HUM	شخص، تفسیر، گروه، عنوان
LOC	شهر، کشور، کوه، ایالت، استان
NUM	کد، عدد، زمان، فاصله، پول، رتبه، درصد، مدت، سرعت، دمای هوا، سایز، وزن

کاهش فضای جستجو: با توجه به نوع طبقه می‌توان فضای جستجو را کاهش داد. به عنوان مثال با دانستن برچسب پرسشی که از نوع مکان است، سامانه بدلیل متن‌ها و پاراگراف‌هایی خواهد گشت که اطلاعاتی از این نوع را داشته باشد.

مشخص کردن پاسخ: دانستن نوع طبقه علاوه‌بر این که فضای جستجو را کاهش می‌دهد، در یافتن پاسخ صحیح از مجموعه پاسخ‌های نامزد تأثیر گذار است؛ به عنوان مثال برای پرسش ۱، برچسب تعلق گرفته از نوع مکانی است، درنتیجه از بین پاسخ‌های نامزد انتخاب شده، پاسخ نهایی باید از نوع طبقه پرسش باشد.

انتخاب راهبرد جستجو: با توجه به نوع طبقه می‌توان راهبرد جستجو را تعیین کرد. به عنوان مثال در پرسش ۲ با توجه به اینکه نوع پرسش definition می‌باشد، می‌توان راهبرد یافتن پاسخ را به صورت از پیش تعریف شده "ethology is a ..." در نظر گرفت.

Q2: What is ethology?

در ادامه این مقاله ابتدا در بخش ۲ کارهای انجام شده در زمینه دسته‌بندی پرسش‌ها بیان می‌شود، در بخش ۱-۲ دسته‌بندهای مورد استفاده در این روش پیشنهادی معرفی می‌شود. در بخش ۳ روش پیشنهادی بیان شده است و در بخش ۴ پیاده‌سازی و ارزیابی و در نهایت در بخش ۵ نتیجه‌گیری بیان می‌شود.

² Fine

با افزایش و توسعه وب، نیاز است تا موتورهای جستجو هوشمندتر از قبل رفتار کنند. در بیشتر موارد کاربران به جای فهرستی از استناد به بخش کوچکی از اطلاعات نیاز دارند تا به جای مطالعه کل استناد، بخش کوچکی از سند را مطالعه کنند. با توجه به نیاز کاربران، نسل بعدی موتورهای جستجو، سامانه‌های پرسش و پاسخ است، سامانه‌هایی که به کاربر اجازه می‌دهد؛ سؤال را در ساختار زبان طبیعی به سامانه بدهد و پاسخ را به صورت دقیق دریافت کند. هدف تولید و گسترش سامانه‌های پرسش و پاسخ، دادن پاسخ دقیق و کوتاه به پرسش داده شده به زبان طبیعی است. دسته‌بندی پرسش جزء مهم‌ترین بخش‌های سامانه‌های پرسش و پاسخ است.

دانسته‌بندی پرسش را می‌توان، به عمل تعیین یک مقدار منطقی به دو تایی $q_j, c_i \in Q \times C$ تعریف کرد. که در اینجا Q مجموعه پرسش‌ها و $C = \{c_1, \dots, c_{|C|}\}$ مجموعه از پیش تعیین شده برای دسته‌های پرسش است. مقداردهی q_j, c_i با T بیان کننده تعلق پرسش q_j به c_i و مقدار F بیان کننده عدم تعلق این پرسش به دسته c_i می‌باشد.

سامانه‌های پرسش و پاسخ مختلف، معماری‌های متفاوت دارند؛ اما در همه آنها بخشی برای دسته‌بندی پرسش وجود دارد که نقشی مهم را ایفا می‌کنند [11]. حدود ۳۶/۴٪ از خطاهای یک سامانه پرسش و پاسخ، به علت دسته‌بندی نادرست سؤال است [14]. تأثیر سامانه‌های دسته‌بندی پرسش‌ها در افزایش دقت سامانه‌های پرسش و پاسخ غیر قابل انکار و در [14] این تأثیر نشان داده شده است. به عنوان مثال برای پرسش ۱ برچسب تعلق گرفته Location است، که مشخص می‌کند پاسخ مورد نیاز به پرسش داده شده از نوع مکان است. درواقع نوع پاسخ مربوط به پرسش را پیش‌بینی می‌کند، به همین دلیل به دسته‌بندی پرسش پیش‌بینی کننده نوع پاسخ گفته می‌شود.

Q1: What country's capital is Tirana?

دسته‌های متفاوتی برای پرسش‌ها مشخص شده است؛ اما بیشترین کاربرد را دسته‌های معرفی شده در [10] دارد، که در آن برای پرسش‌ها دو دسته‌بندی Riz¹ با ۶ دسته و درشت² با ۵۰ دسته ارائه شده است. این دسته‌بندی‌ها در جدول ۱ آورده شده است. در این مقاله تمرکز ما بر روی دسته Riz با ۶ دسته است.

¹ Coarse



پیچیده باشد؛ ساده در حد ویژگی‌های کلامی یا پیچیده مثل ویژگی‌ها نحوی و معنایی.

علاوه‌براین، روش‌های ترکیبی نیز وجود دارد که از هر دو روش مبتنی بر یادگیری و مبتنی بر قانون استفاده می‌کنند [18، 17]. روش ارائه شده در این مقاله نیز در این دسته قرار دارد.

۱-۲- دسته‌بندها

از الگوریتم‌های دسته‌بندی مورد استفاده برای دسته‌بندی پرسش‌ها می‌توان به ماشین بردار پشتیبان [11]، شبکه‌های بیزی^۳ [19]، درخت‌های تصمیم^۴ [19]، SNoW [10] و BPNN [11] اشاره کرد. در این میان، از مجموع کارهای انجام شده ماشین بردار پشتیبان بهترین کارآیی را داشته است.

در این مقاله از دو دسته‌بند مبتنی بر ماشین بردار پشتیبان و مبتنی بر نمایش پراکنده استفاده شده است. همچنین ویژگی‌های مورد استفاده برای هر دسته‌بند، متفاوت است، که انتخاب براساس نتایج دسته‌بندها صورت پذیرفته شده است.

۱-۱- ماشین بردار پشتیبان

ماشین بردار پشتیبان، با این فرض که دسته‌ها به صورت خطی جداپذیرند، ابرصفحه‌هایی با حداقل حاشیه^۵ را به دست می‌آورد که دسته‌ها را جدا کند. در داده‌های با ابعاد زیاد این دسته‌بند جزء سریع‌ترین دسته‌بندها است. این دسته‌بند نوع کرنلی محسوب می‌شود؛ چرا که در این روش برای جداکردن دسته‌ها، داده‌ها را توسط تابعی تحت عنوان تابع کرنل به ابعادی بیشتر نگاشت می‌کند. در دسته‌بندی پرسش‌ها به طور معمول از کرنل خطی استفاده می‌شود. در این مقاله نیز از کرنل خطی استفاده شده است.

۲-۱- نمایش پراکنده

در سامانه معادلات خطی $A \in \mathbb{R}^{m \times n}$ ، $A < n$ باشد، آن سامانه را فرومی‌عنیم می‌گویند. در این سامانه تعداد مجهول‌ها بیشتر از تعداد معادلات است؛ درنتیجه بی‌نهایت جواب برای آن وجود دارد. بهمنظور محدود کردن تعداد پاسخ‌ها و ارزیابی مطلوبیت هر پاسخ ممکن x ، از یک تابع $(x)J$ استفاده شده

۲- مروری بر کارهای گذشته

به‌نظر می‌رسد ساده‌ترین راه برای دسته‌بندی پرسش‌ها استفاده از قواعد دستنویس از پیش تعریف شده است. قوانین مورد استفاده می‌تواند ساده و پیچیده باشد. ساده مثل "اگر پرسشی که با whom یا who شروع شود به کلاس شخص دسته‌بندی می‌شود" و "اگر پرسشی که با where شروع شود با برچسب مکانی برچسب زده می‌شود". همچنین این قوانین می‌توانند پیچیده باشند و برای بررسی، نیاز باشد توسط ابزارهای پردازش زبان طبیعی، مورد پردازش واقع شوند از این سامانه‌ها می‌توان به [18] و [16] اشاره کرد.

در اکثر موارد استخراج قوانین مورد استفاده به صورت دستی انجام می‌پذیرد [4، 16] و [13]. اما در بعضی موارد این قوانین به صورت خودکار استخراج می‌شوند [6]. در [6] قواعد در قالب ماشین‌های حالات متناهی، بیان شده است، این قواعد از روشنی خودکار و با استفاده از مثال‌های آماده، و پس از حذف ایستوازه‌ها، و با استفاده از کلیدوازه‌ها استخراج شده‌اند و براساس فراوانی رخداد کلیدوازه‌ها در ترتیب پرسش مورد بررسی واقع می‌شوند؛ اما در کل روش‌های مبتنی بر یادگیری مزايا و معایب خاص خود را دارد. برخی مزايا و معایب این روش‌ها عبارتنداز:

- محاسبات سریع و ارزان دارند.
- این قوانین، حداکثر انعطاف‌پذیری را دارند.
- قوانین فقط برای مجموعه داده که ایجاد شده‌اند، دقت خوبی دارند.
- فرآیند استخراج قوانین از پرسش‌ها کاری خسته‌کننده و وقت‌گیر و نیاز به کار و صرف وقت زیادی است.
- تعداً قوانین استخراجی ممکن است بسیار زیاد باشد، به‌نحوی که مدیریت آن مشکل شود.

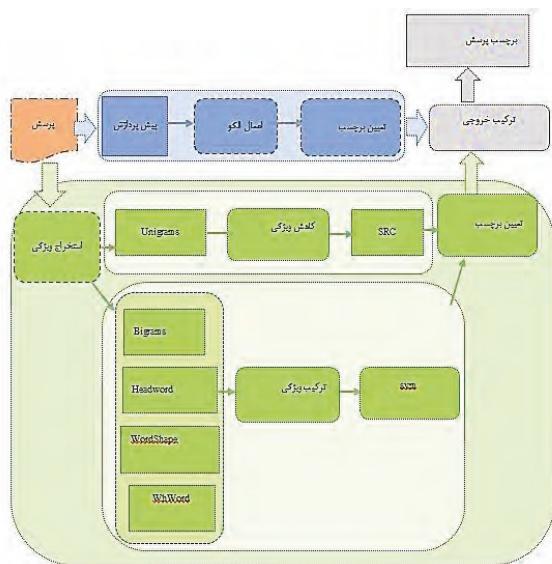
روش‌های مبتنی بر یادگیری، برای بخش یادگیری، ابتدا نیازمند داده‌های برچسب خورده هستند؛ سپس مدل‌های یادگیری بر روی این داده‌ها، آموزش داده می‌شوند. در این روش‌ها برای دسته‌بندی، پرسش‌ها در قالب مجموعه‌ای از ویژگی‌ها در نظر گرفته می‌شوند؛ و سعی می‌شود با توجه به ویژگی‌های استخراج شده از داده‌های برچسب خورده، الگوها را به صورت خودکار استخراج کنند. بنابراین در این روش‌ها انتخاب ویژگی‌ها و دسته‌بند اهمیت زیادی دارد. ویژگی‌های مورد استفاده می‌تواند خیلی ساده یا

³ Sparse Network of Winnows

⁴ Maximum margin

پردازش متن برای نخستین بار و همچنین ارائه معماری با استفاده از ترکیب دسته‌بندها اشاره کرد که باعث بهبود قابل ملاحظه در نتایج نهایی شده است.

است و پاسخی با کمترین مقدار تابع ارزیابی، به عنوان مطلوب‌ترین پاسخ است. در این صورت مسئله به یک مسئله بهینه‌سازی تبدیل می‌شود. مسئله بهینه‌سازی کلی به صورت رابطه ۱ می‌شود.



(شکل-۱): معماری سیستم دسته‌بند ترکیبی
(Figure-1): Architecture of Ensemble Classifier System

۱-۳- دسته‌بند مبتنی بر قانون

برای دسته‌بندی مبتنی بر قانون ابتدا طی یک مرحله پیش‌پردازش درخت تجزیه‌پرسش ایجاد و اسامی خاص پرسش توسط ابزار شناسایی اسامی خاص و Gazetteer اسامی خاص پرسش شناسایی می‌شوند. البته Gazetteer را می‌توان شناسایی‌کننده اسامی خاص در نظر گرفت که در آن اسامی در گروه‌های جدا به صورت فهرستی از قبل آماده، گردآوری شده است. با توجه به این که اسامی در گروه‌های جدا بیان می‌شوند، می‌توان در موارد خاص از آنها استفاده کرد. برای اکثر شناسایی‌کننده‌های اسامی خاص، اسامی شهرها و کشورها تفاوتی ندارد و برای هر دو برچسب مکان تعلق می‌گیرد؛ اما در Gazetteer این اسامی به صورت جدا، فهرست شده است. همچنین شناسایی‌کننده اسامی خاص، اسامی مشاغل را شناسایی نمی‌کند. در ادامه برای ایجاد قوانین برای دسته‌بندی پرسش از درخت تجزیه و اسامی شناسایی‌شده استفاده می‌شود. قوانین ایجاد شده در دسته‌بند مبتنی بر قانون در قالب عبارات منظم می‌باشند. این قوانین با توجه به ساختار لغوی و نحوی پرسش‌ها ایجاد شده است.

$$(P_J): \min_x J(x) \quad \text{Subject to } b = AX \quad (1)$$

شناخته‌شده‌ترین انتخاب برای تابع $J(x)$ ، مربع نرم اقلیدسی، یعنی $\|X\|_2^2 = \|J(x)\|^2$ است.

۲-۲- دسته‌بندی مبتنی بر نمایش پراکنده

در [21] با استفاده از نمایش پراکنده، الگوریتمی برای دسته‌بندی ارائه شده است که در آن برای هر طبقه آم، $\delta_i: \mathbb{R}^n \rightarrow \mathbb{R}^n$ را به عنوان یک تابع مشخصه در نظر می‌گیرد تا ضرایب مرتبط با نمونه‌های طبقه آم را از بردار ضرایب پراکنده، انتخاب کند. برای $x \in \mathbb{R}^n$ حاصل از مسئله بهینه‌سازی، $\delta_i(x) \in \mathbb{R}^n$ یک بردار جدید همانند x می‌شود، با این تفاوت که در آن فقط درایه‌های مرتبط با کلاس آم مقدار دارند و مابقی، درایه‌های صفر هستند. با استفاده از ضرایب مرتبط با طبقه آم انتخاب شده توسط (x, δ_i) ، نمونه آزمون y تقریب زده می‌شود، به طوری که $(x, \delta_i) \approx y$ ؛ سپس مبتنی بر کمینه‌ترین باقیمانده بین y و \hat{y} در میان تمام طبقه‌ها، برچسب نمونه آزمون را تعیین می‌کند؛ یعنی همانند رابطه ۲:

$$\min_i r_i(y) \doteq \|y - A\delta_i(x)\|_2 \quad (2)$$

۳- روش پیشنهادی

همان‌طور که بیان شد در روش ارائه شده از یک دسته‌بند مبتنی بر قاعده و دو دسته‌بند مبتنی بر یادگیری استفاده شده است. معماری روش پیشنهادی در شکل (۱) آورده شده است.

مجموعه قوانین استخراج شده در بخش مبتنی بر قانون از داده‌های یادگیری استخراج می‌شود و توسط آنها دسته‌بند پرسش‌های مرحله آزمون مشخص می‌شود. برای روش‌های مبتنی بر یادگیری، ابتدا مجموعه ویژگی‌ها از پرسش‌ها استخراج می‌شود و در ادامه دسته‌بندی داده‌ها توسط این مجموعه ویژگی طی دو مرحله یادگیری و آزمون انجام می‌پذیرد.

به‌طور کلی از نوآوری‌های روش ارائه شده می‌توان به‌ایده استفاده از دسته‌بند مبتنی بر نمایش پراکنده برای

هر یک از کلمات است که برای این منظور نیاز به استفاده از برچسب‌گذار اجزای سخن است. به عنوان مثال برای این دسته می‌توان به پرسش سه اشاره کرد:

Q3: What is the Olympic motto?

خروجی حاصل از برچسب‌گذار اجزای کلام مربوط به این پرسش به صورت زیر است.

WP/What VBZ/is DT/the NNP/Olympic NN/motto.?

$$\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N) \quad (3)$$

با توجه به خروجی برچسب‌گذار اجزای سخن، این پرسش شرایط اعمال این قانون را دارد.
به عنوان مثالی دیگر پرسش هشت بیان می‌کند "درصورتی که پرسش با what/which شروع و در ادامه اسمی از نوع شغل انسانی آورده شود، این پرسش از نوع HUM خواهد بود". برای تشخیص اسمی شغل انسانی از ابزار gazetteer استفاده می‌شود. به عنوان مثال در پرسش چهار کلمه actor اسم شغل انسانی می‌باشد و بعد از کلمه پرسش آمده است درنتیجه شرط اعمال قانون را دارد.

Q4: What actor first portrayed James Bond?

باید توجه داشت ترتیب اعمال قواعد اهمیت زیادی

دارد و همچنین سعی شده است تا قواعد به جهت افزایش در دقت به صورت ترکیبی از شرط باشد؛ به عنوان مثال در پرسش پنج به جهت وجود شغل انسانی ممکن است، پرسش به HUM برچسب‌گذاری شود؛ اما با توجه به قاعده هفت از جدول ۲ نوع پرسش DESC برچسب‌گذاری می‌شود. با توجه به اینکه قواعد جدول ۲ از قواعد با اولویت هستند و در ابتدا اعمال می‌شوند سامانه به درستی فرآیند برچسب‌گذاری را انجام می‌دهد.

Q5: How do doctors diagnose bone cancer?

۲-۳- دسته‌بند مبتنی بر یادگیری

برای دسته‌بند مبتنی بر یادگیری از دسته‌بند مبتنی بر نمایش پراکنده و ماشین بردار پشتیبان استفاده شده است. ویژگی‌های مورد استفاده برای دسته‌بندها، مستقل از یکدیگرند و این انتخاب با توجه به عملکرد آنها بر روی ویژگی‌ها است. همان‌طور که در بخش بعد بیان خواهد شد با توجه به نتایج حاصل شده، ویژگی‌های مورد استفاده برای دسته‌بند مبتنی بر نمایش پراکنده، کاهش داده Unigrams و Headword، Bigrams، برای ماشین بردار پشتیبان WordShape و WhWord است.

(جدول-۲): برخی از قواعد مورد استفاده برای دسته‌بند

مبتنی بر قاعده

(Table-2): Some of the rules used in the rule-based classifier

	Label	Pattern
1	DESC	پرسش‌هایی که با یک what is/are and شروع می‌شوند و با همراه شده a, an or the در ادامه با یک یا چند کلمه همراه هستند.
2	DESC	پرسش‌هایی که با what do/does شروع شده و با mean خاتمه می‌یابند.
3	DESC	پرسش‌هایی که با what causes/cause آغاز می‌شوند.
4	DESC	پرسش‌هایی که با what is/are آغاز شده و با known for خاتمه می‌یابند.
5	DESC	پرسش‌هایی که با why آغاز می‌شوند.
6	DESC	پرسش‌هایی که با what is/are آغاز می‌شوند و با فعل همراه نیستند.
7	DESC	پرسش‌هایی که با how is/are/did/does/do/ can آغاز می‌شوند.
8	HUM	پرسش‌هایی که با what/which همراه با اسمی شغل همراه هستند.
9	ENTY	پرسش‌هایی که با How do you say آغاز می‌شوند.
10	ABBR	پرسش‌هایی که با what does/do آغاز شده و با stand for همراه هستند.

در جدول (۲) بخشی از قوانین مورد استفاده آورده شده است. ترتیب اعمال این قوانین در نتیجه دسته‌بند تأثیرگذار است و باید به آن توجه داشت، چون بعضی از الگوها خاص و بعضی عام هستند و قوانین خاص باید قبل از قوانین عام قرار گیرند. به عنوان مثال در قانون ۷ بیان شده است، "درصورت وجود how is/are/did/does/do/can ابتدای پرسش، نوع پرسش DESC خواهد بود"، همچنین در قانون ۹ بیان شده است "درصورت وجود عبارت How do you say در ابتدای پرسش، نوع پرسش ENTY خواهد بود".

قانون ۷ قانونی کلی و قانون ۹، قانونی خاص است. درصورت عدم توجه به ترتیب این قوانین، موارد مربوط به قانون ۹ به اشتباه توسط قانون هفت دسته‌بندی می‌شوند. بدليل بروز حالات استثنای زیاد و برای افزایش دقت قوانین استخراج شده از ابزارهای پردازش زبان طبیعی مثل برچسب‌زن اجزای سخن و شناسایی کننده اسمی خاص و Gazetteer استفاده شده است.

به عنوان مثال، قانون شش در حالتی رخ می‌دهد که "بعد از what یکی از افعال is/are رخ دهد؛ و در ادامه دیگر هیچ فعلی رخ ندهد؛ در این صورت پرسش از نوع DESC خواهد بود". برای اعمال این قانون نیاز به دانستن برچسب

ماتریس متعامد سط्रی بوده و ستون‌های آن بردارهای یکه سمت راست نامیده می‌شوند.

برای کاهش ویژگی تا ابعاد k از ماتریس U ، زیر ماتریس U_k با ابعاد $d \times k$ ساخته می‌شود که شامل k ستون ابتدایی ماتریس U است ماتریس با ابعاد کاهش یافته به صورت رابطه^۴ ایجاد می‌شود.

$$R = Q^T U_k \quad (4)$$

ابعاد این ماتریس $n \times k$ خواهد بود که سطراها بیان کننده پرسش‌ها و ستون‌ها ویژگی پرسش‌ها است. **Bigram**: این ویژگی بخشی از n تایی‌ها است. به جهت زیاد بودن ابعاد این ویژگی، فقط از دوتایی ابتدایی هر پرسش استفاده می‌شود. به عنوان مثال برای پرسش پنج این ویژگی *How-many* است.

Wh-words: این ویژگی کلمات پرسشی درون پرسش است. با توجه به اینکه انواع این کلمات هشت مورد بیشتر نیستند (*rest, what, which, when, where, who, how, why*) ابعاد این ویژگی هشت است. به عنوان مثال برای پرسش شش این ویژگی *what* است.

Q6: What is the longest river in the world?

Word shapes: این ویژگی مربوط به ظاهر کلمات درون پرسش است. پنج نوع ظاهری برای کلمات مشخص شده است. *other, All digits, lower case, upper case, mixed* و *zir* است. به عنوان مثال برای پرسش دو این ویژگی‌ها به صورت زیر است.

$$\text{Word-shapes} = \{(lowercase, 4) (mixed, 4) (digit, 1) (other, 1)\}$$

۴-۳- ویژگی‌های نحوی

ویژگی نحوی مورد استفاده برای دسته‌بندی کلمه اصلی است که توسط درخت تجزیه از پرسش استخراج می‌شود. **کلمه اصلی^۵**: کلمه اصلی پرسش، به طور معمول به عنوان مفیدترین کلمه یک پرسش از نظر اطلاعاتی تعریف می‌شود. در واقع هدف پرسش را بیان می‌کند، مشخص می‌کند پرسش انتظار چه نوع پاسخی را دارد[7]. تشخیص صحیح کلمه اصلی در پرسش می‌تواند باعث افزایش دقت در تشخیص دسته پرسش شود. به عنوان مثال در پرسش سه کلمه city، city کلمه اصلی پرسش است. در این پرسش وجود کلمه city کمک زیادی در تشخیص دسته پرسش که LOC است، می‌کند.

در دسته‌بندی مبتنی بر یادگیری از ویژگی‌های متفاوتی استفاده شده است که می‌توان آنها را در دو دسته تقسیم کرد. ویژگی‌های لغوی، نحوی دسته‌بندی نمود.

۳-۳- ویژگی‌های لغوی

ویژگی‌هایی لغوی مربوط به پرسش‌ها به طور معمول براساس کلمات درون پرسش استخراج می‌شوند. در دسته‌بندی پرسش‌ها همانند نمایش اسناد، پرسش‌ها به صورت بردار نمایش داده می‌شود. به عنوان مثال پرسش X به صورت رابطه^۳ نمایش داده می‌شود.

در این رابطه^۷ بیان کننده فرکانس تعداد ویژگی xi ام در پرسش x و N تعداد کل ویژگی‌ها است. ویژگی‌های لغوی مورد استفاده به صورت زیر است:

Unigram: در واقع همان فهرست کلمات درون پرسش است. رخداد تک‌تک کلمات درون پرسش است. به عنوان مثال برای پرسش ۵ این مجموعه ویژگی به صورت زیر می‌باشد:

Q5: How many Grammys did Michael Jackson win in 1983?

$$x = \{(How, 1), (many, 1), (Grammys, 1), (did, 1), (Michael, 1), (Jackson, 1), (win, 1), (in, 1), (1983, 1), (? , 1)\}$$

همان‌طور که در ادامه بیان می‌شود، ابعاد این ویژگی خیلی بیشتر از تعداد داده‌ها است؛ به همین جهت ابعاد این ویژگی توسط SVD کاهش داده و از کاهش یافته آن استفاده می‌شود. طبق [11] این ویژگی با ابعاد ۴۰۰ بهترین نتیجه را به همراه دارد به همین جهت، ابعاد این ویژگی را تا ۴۰۰ کاهش داده و به جای کل ویژگی‌ها استفاده می‌شود.

برای کاهش ویژگی با استفاده از SVD ابتدا ماتریس Q ایجاد می‌شود که ردیف‌های آن بیان کننده ویژگی‌ها و ستون‌های آن بیان کننده پرسش‌ها است. ابعاد این ماتریس $d \times n$ است d تعداد ویژگی‌ها و n تعداد پرسش‌ها می‌باشد. هر عضو همانند $Q_{i,j}$ بیان کننده مقدار ویژگی i ام برای پرسش j است. ماتریس Q با ابعاد $m \times n$ به سه ماتریس $U = [u_{ij}]$ ماتریس متعامد^۱ ستونی $m \times m$ بوده و ستون‌های آن بردارهای یکه سمت چپ نامیده می‌شوند؛ $S = diagonal(\sigma_1, \sigma_2, \dots, \sigma_n)$ ماتریس قطری است که عناصر قطر اصلی آن مقادیر یکه غیرمنفی $m \times n$ هستند که به صورت نزولی مرتبط شده‌اند و $V = [v_{ij}]$ هم

² Head Word

¹ Orthonormal



انتخاب کلید اصلی مربوط به پرسش، به اسمی اولویت بیشتری تعلق گرفته است. به عنوان مثال در جدول (۳) مجموعه این قوانین ارائه شده است.

در این جدول ستون نخست گره‌های سمت چپ قوانین را مشخص می‌کند که گره‌های غیرپایانی است. ستون دوم جهت جستجوی سمت راست قوانین را مشخص می‌کند. که می‌تواند براساس دسته^۱ یا موقعیت^۲ صورت گیرد؛ و ستون سوم فهرست اولویت را بیان می‌کند.

منظور از $L\text{-}b\text{-}C$ است که بیان می‌کند از چپ‌ترین فرزند، به ترتیب عکس فهرست اولویت عمل جستجو انجام می‌شود و بروز هر تناظری به عنوان کلید اصلی برگردانده می‌شود؛ اما منظور از $L\text{-}b\text{-}P$ position است، الگوریتم ابتدا موارد درون فهرست اولویت را کنترل و تناظر این موارد در فرزندان را از چپ به راست بررسی می‌کند و نخستین رویداد به عنوان کلمه اصلی برگردانده می‌شود. $R\text{-}b\text{-}C$ و $R\text{-}b\text{-}C$ هم روالی همانند b left by دارند؛ اما عملیات در سمت عکس موارد قبلی اجرا می‌شود. این قوانین، قوانین اصلاح شده Collins است که برای اعمال این قوانین نیاز است درخت تجزیه پرسش توسط تجزیه‌گر ایجاد شود و این قوانین به صورت از بالا به پایین بر روی درخت تجزیه اعمال می‌شود.

اما قوانین ایجاد شده برای همهٔ حالات نتیجهٔ صحیحی را به همراه نداشت. به عنوان مثال برای پرسش شش کلمه اصلی city است، اما با اعمال این قوانین airport را بر می‌گرداند.

Q6: What city is Logan Airport in?

برای رفع این مشکل می‌توان قوانینی را به عنوان استثنای قبلي از اعمال قوانین جدول ۳ در نظر گرفت. اگر $WHPP$, $WHNP$, $WHADVP$ یا $WHADJP$ بیش از یک فرزند داشته باشد، اسم یا گروه اسمی درون عبارت به عنوان کلمه اصلی انتخاب شود. که در این حالت نتیجهٔ انتخاب کلمه اصلی صحیح خواهد بود.

بعاد هر یک از ویژگی‌ها به تفکیک نوع آن در جدول ۴ آورده شده است.

۳-۵-۳- ترکیب دسته بندها

استفاده از نتایج چند دسته‌بند با عنوان یادگیری دسته‌جمعی، یک رویکرد مؤثر در یادگیری ماشینی است که در آن به منظور بهبود دقت یادگیری، نتایج دسته‌بندها با

² Position

استخراج کلمه اصلی از پرسش یکی از چالش‌های مهم می‌باشد، استخراج کلمه اصلی با استفاده از ساختار نحوی پرسش استخراج می‌شود، برای این منظور از درخت تجزیه پرسش استفاده می‌شود.

استخراج کلمه اصلی از پرسش یکی از چالش‌های مهم می‌باشد، استخراج کلمه اصلی با استفاده از ساختار نحوی پرسش استخراج می‌شود، برای این منظور از درخت تجزیه پرسش استفاده می‌شود.

نخستین بار ایده استخراج کلمه اصلی از ساختار درخت تجزیه توسط Collins در [2] ارائه شد. در [2] تعدادی قانون برای استخراج کلید اصلی ارائه شده است که به قانون‌های Collins شناخته می‌شوند.

(جدول-۳): قوانین استخراج کلید اصلی [11]

(Table-3): Primary key extraction rules [11]

Parent	Direction	Priority List
ROOT	$L\text{-}b\text{-}C$	S, SBARQ
S	$L\text{-}b\text{-}C$	VP, FRAG, SBAR, ADJP
SBARQ	$L\text{-}b\text{-}C$	SQ, S, SINV, SBARQ, FRAG
SQ	$L\text{-}b\text{-}C$	NP, VP, SQ
NP	$R\text{-}b\text{-}P$	NP, NN, NNP, NNPS, NNS, NX
PP	$L\text{-}b\text{-}C$	WHNP, NP, WHADVP, SBAR
WHNP	$L\text{-}b\text{-}C$	NP, NN, NNP, NNPS, NNS, NX
WHADVP	$L\text{-}b\text{-}C$	NP, NN, NNP, NNPS, NNS, NX
WHADJP	$L\text{-}b\text{-}C$	NP, NN, NNP, NNPS, NNS, NX
WHPP	$R\text{-}b\text{-}C$	WHNP, WHADVP, NP, SBAR
VP	$R\text{-}b\text{-}C$	NP, NN, NNP, NNPS, NNS, NX, SQ, PP
SINV	$L\text{-}b\text{-}C$	NP
NX	$L\text{-}b\text{-}C$	NP, NN, NNP, NNPS, NNS, NX, S

در یک قاعدة گرامری آزاد از بافت به صورت $X \rightarrow Y_1 \dots Y_2$ که X در درخت تجزیه گره غیرپایانی هستند، قواعد اصلی مشخص می‌کنند که کدام یک از گره‌های غیرپایانی، قاعدة اصلی X است. برای مثال برای دستور $SBARQ \rightarrow WHNP\ SQ$ قوانین Collins مشخص می‌کنند که کلمه اصلی در گره غیرپایانی SQ قرار دارد. این روال به صورت تکرارشونده تا زمان رسیدن به گره پایانی ادامه می‌باید.

در [11], [18] و [7] مجموعه قوانین برای استخراج کلید اصلی از پرسش طراحی شده است، در این قواعد برای

¹ Category

۵۵۰۰ پرسش برچسب‌خورده به عنوان مجموعه یادگیری و پانصد پرسش برچسب‌خورده به عنوان مجموعه آزمون است. با توجه به این که در این مجموعه داده از مجموعه پرسش‌های TREC استفاده شده است، به آن TREC نیز گفته می‌شود.

نحوه توزیع سؤالات بخش یادگیری و آزمون در شکل (۲) آورده شده است. برای هر دسته‌بند ویژگی‌های متفاوتی استفاده شده است که این انتخاب براساس نتیجه آنها صورت گرفته است.

(جدول-۵): نتایج حاصل از دسته‌بندها برای ویژگی‌های متفاوت

(Table-5): Classifiers result on different features

U	H	H-WS	H-WS-LB	WH-H-WS-LB	
82.2	68.3	72.6	90	92.2	svm
91.2	66.4	68.6	87.5	88.3	src

آزمایش بالا بر روی داده‌های آموزش با k-fold=10 اجرا شده است.

برای دسته‌بند مبتنی بر ماشین بردار پشتیبان بهترین ترکیب WH-H-WS-LB با ۹۲,۲ درصد و برای دسته‌بند مبتنی بر نمایش پراکنده ۹۱,۲ است، بنابراین از ترکیب دو دسته‌بند با ویژگی‌های یادشده عملیات دسته‌بندی را اعمال می‌کنیم.

نتایج حاصل از دسته‌بندها برای هریک از دسته‌ها در جدول (۶) آورده شده است.

با توجه اطلاعات جدول می‌توان نتیجه گرفت روش مبتنی بر نمایش پراکنده برای تمامی دسته‌ها عملکردی به طور تقریبی یکسان دارد، اما در روش مبتنی بر قانون اختلاف مابین صحت^{۱۰} و فراخوانی^{۱۱} بیش از روش مبتنی بر نمایش پراکنده است و این به علت نحوه اعمال قوانین است، به عنوان مثال برای سؤالات با طبقه Enty، ایجاد قوانین برای این دسته به جهت نوع و ساختار پرسش‌ها به دلیل بروز استثناهای فراوان مشکل است. به همین جهت در ساختار و ترتیب قوانین مشخص کردن این دسته در انتهای قرار گرفته است و در عدم تطابق پرسش با هیچ یک از قوانین، به این دسته تعلق می‌گیرد در نتیجه باید انتظار داشت فراخوانی مربوط به این دسته زیاد، اما صحت آن کم باشد که نتایج حاصله این موضوع را تأیید می‌کند.

⁷ Decision Template

⁸ Dempster-Shafer Combination

⁹ <https://gate.ac.uk/>

¹⁰ precision

¹¹ recall

یکدیگر ترکیب شده و یک سامانه مرکب شکل می‌گیرد. خروجی الگوریتم‌های مختلف دسته‌بندی در یکی از شکل‌های زیر بیان می‌شود^[۵].

الف- خروجی تک طبقه^۱: در این نوع، دسته‌بند فقط یک برچسب طبقه‌ای، برای الگوی ورودی ارائه می‌کند.

ب- خروجی چند طبقه مرتباً شده^۲: در این حالت، دسته‌بند تعلق الگوی ورودی به طبقه‌های مختلف را به صورت یک فهرست مرتب ارائه می‌کند. طبقه با بیشترین تعلق در ابتدای فهرست و طبقه با کمترین تعلق در انتهای آن قرار دارد.

(جدول-۴): تعداد ابعاد ویژگی‌های استخراجی

(Table-4): the number of extracted features dimensions

H-W	L-B	W-W	W-S	Unigrams	
1964	1010	8	5	9775	ابعاد

نحوی
لغوی
لغوی
لغوی
نحوی

ج- خروجی چند طبقه امتیازدار^۳: در این شکل، دسته‌بند برای تعلق الگوی ورودی به هر کدام از طبقه‌ها یک مقدار عددی تخصیص می‌دهد. این مقدار عددی بیان‌گر میزان امتیازی است که با توجه به معیار دسته‌بندی، برای تعلق الگوی ورودی به آن طبقه محاسبه شده است.

متداول‌ترین تقسیم‌بندی برای روش‌های ترکیب خروجی دسته‌بندها، تقسیم‌بندی آنها بر حسب نوع خروجی الگوریتم دسته‌بندی است که بر اساس آن روش‌های ترکیب به سه دسته تقسیم می‌شوند. خروجی دسته‌بندهای مورد استفاده تک‌طبقه هستند به این جهت از روش‌های ترکیبی تک‌طبقه استفاده شده است، روش‌هایی چون رأی‌گیری^۴، فضای دانش رفتار^۵، بیز ساده^۶، کلیشه تصمیم^۷ و دمپستر شفر^۸ که نتایج هر یک در بخش بعد آورده شده است.

۴- پیاده‌سازی و ارزیابی

برای ابزارهای پردازش زبان طبیعی مورد استفاده (تجزیه‌گر، برچسبزن اجزای کلام و شناسایی‌کننده اسامی خاص) از ابزار دانشگاه استنفورد [۳]، [۱۲] و [۲۰] و همچنین برای Gazetteer از ابزار موجود در مجموعه Gate^۹ استفاده شده است. برای ارزیابی عملیات دسته‌بندی پرسش‌ها از داده‌های استاندار UIUC استفاده شده است، این مجموعه شامل

¹ Abstract level

² Rank level

³ Measurement level

⁴ Voting

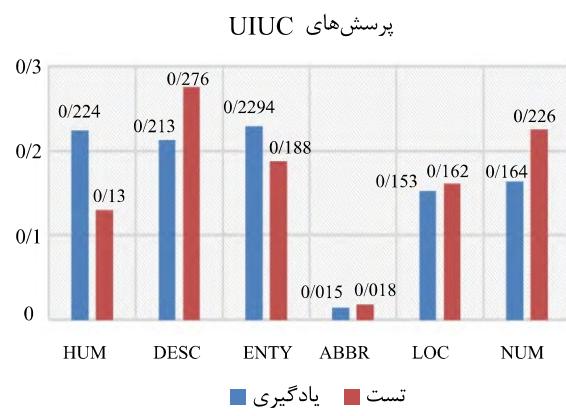
⁵ Behavior knowledge space

⁶ Naive Bayes



با توجه به نتایج شکل (۳)، امتیاز F1 مربوط به برای سه دسته LOC، NUM، HUM بیشترین مقدار و دسته‌بند مبتنی بر قاعده ABBR و در انتهای روش مبتنی بر SVM بهترین امتیاز را در DESC دارد. در ساده‌ترین حالت، اگر دسته‌بندها به گونه‌ای ترکیب شوند که برای هر دسته از پرسش‌ها، با توجه به نتایج بیان شده، از دسته‌بندی استفاده شود که نتیجه قابل قبول‌تری دارد. ترکیب سامانه‌ها ثمربخش خواهد بود.

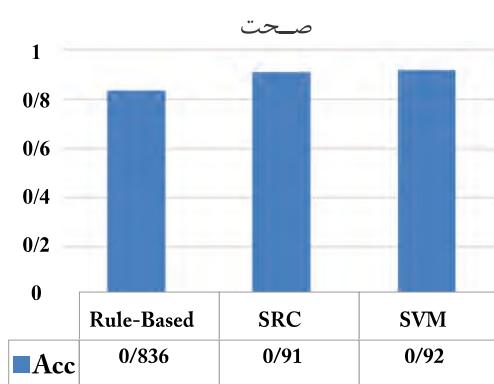
با توجه به شکل (۴)، صحت^۱ مربوط به هر یک از دسته‌ها در کل مجموعه داده‌ها آورده شده است، روش مبتنی بر ماشین بردار پشتیبان بالاترین امتیاز را دارد، اما همان‌طور که بیان شد در این دسته‌بند اختلاف مابین دسته‌های پرسش‌ها زیاد است و با اصلاح نتایج این دسته‌ها می‌توان به نتایج بهتری دست یافت.



(شکل-۲): نسبت برچسب پرسش‌های موجود در UIUC

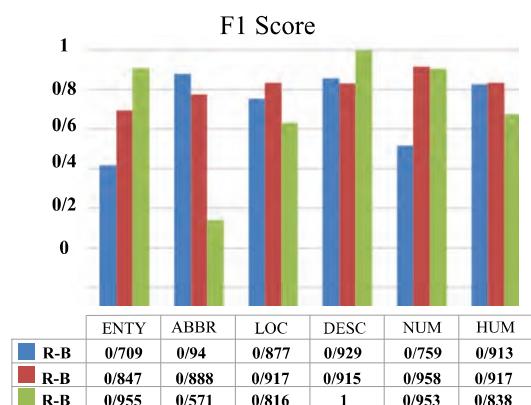
(Figure-2): The UIUC questions tag ratio همچنین دقیق دسته‌بند مبتنی بر قانون برای بعضی از دسته‌ها بسیار خوب (مثل دسته DESC) و برای بعضی دسته‌ها، نتیجه قابل قبولی به همراه ندارد (ABBR).

با توجه به نتایج دسته‌بندها برای دسته‌های متفاوت، می‌توان انتظار داشت، نتیجه حاصل از ترکیب این دسته‌بندها نتیجه قابل قبول و بهتر از هر یک از دسته‌بندها به صورت جدا شود.



(شکل-۴): امتیاز صحت

(Figure-4): Accuracy Score



(شکل-۳): نتایج دسته‌بند مبتنی بر نمایش قانون، SRC و SVM

(Figure-3): The results from SRC, SVM and the Rule-based classifier

(جدول-۶): نتایج حاصل از دسته‌بندها برای ویژگی‌های مختلف

(Table-6): Classifiers results on different features

	%NUM	%DESC	%LOC	%ABBR	%ENTY	دسته
84	100	98	62	92	94	معیار
	90	85	90	90	100	دسته
93	89	92	100	94	89	Rule base
	88	94	88	88	86	
92	76	91	100	100	100	SRC
	82	80	66	50	91	
					100	svm

^۱ Accuracy

صورت رخداد در مرحله یادگیری برچسبی در نظر گرفته می‌شود که این برچسب براساس برچسب واقعی پرسش‌ها می‌باشد [1].

در روش بیز ساده ابتدا با توجه به داده‌های آموزشی برای هر طبقه بند D_j ، یک ماتریس سردرگمی، CM^j تشکیل می‌شود. عناصر این ماتریس به صورت $CM^j(k, s)$ هستند.

مقدار درایه $CM^j(k, s)$ بیان گر تعداد الگوهایی است که برچسب واقعی آنها k است، یعنی متعلق به طبقه ω_k هستند، ولی طبقه‌بند D_j آن‌ها را به طبقه ω_s نسبت داده است. با جمع کردن مقادیر عناصر ستون s ماتریس سردرگمی طبقه‌بند D_j ، می‌توان $CM^j(s)$ یعنی تعداد کل عناصری که این طبقه‌بند به طبقه ω_s نسبت داده است را مشخص کرد. در ادامه برچسب طبقه‌ای الگوی ناشناخته X را براساس احتمال رخداد هر یک از کلاس‌ها برای داده X حساب می‌شود. طبقه با بیشترین احتمال به عنوان برچسب نهایی انتخاب می‌شود [1].

در روش کلیشه تصمیم در ابتدا با استفاده از نمونه‌های آموزشی $\{x_1, \dots, x_n\}$ که برچسب‌های طبقه‌ای آنها مشخص است، ماتریس $DP(x)$ ایجاد می‌شود که شامل خروجی طبقه‌بندی $(D_1(x), D_2(x), \dots, D_3(x))$ است. در ادامه ماتریس‌هایی که مربوط به داده‌های با برچسب ω_k با $k=1\dots 6$ را جدا کرده و با متوسط‌گیری از درایه‌های نظیر به نظری ماتریس‌ها، ماتریس DT_k ایجاد می‌شود. در ادامه برای تعیین برچسب هر داده شباهت DP آنرا با تک‌تک DT ‌ها محاسبه کرده و DT که بیشترین شباهت را داردست به عنوان برچسب نهایی انتخاب می‌شود [9].

در روش ثئوری دمپستر شفر برای ترکیب طبقه‌بندی، ابتدا با توجه به رفتار طبقه‌بندی شواهدی از آنها استخراج می‌شود که به عنوان دانش اولیه در پیداکردن درجه عضویت الگو به هر یک از طبقه‌ها مورد استفاده قرار می‌گیرد. برای یک سامانه مرکب شامل L طبقه بند، L بردار مبنای برای هر طبقه به دست می‌آید که مجموعه این بردارها کلیشه تصمیم آن طبقه را می‌سازند. در مرحله آزمایش با توجه به شباهت ماتریس پروفایل تصمیم با کلیشه تصمیم هر طبقه، شواهد مورد نیاز برای روش دمپستر شفر به دست آمده و میزان باور و سرانجام درجه عضویت هر طبقه محاسبه می‌شود. طبقه با بیشترین درجه عضویت، طبقه الگوی ورودی خواهد بود [1].

استفاده از ترکیب نتایج طبقه‌بند یکی از روش‌های افزایش کارایی سامانه‌های بازشناسی الگو است. برای مفید واقع شدن ترکیب طبقه‌بندیها باید طبقه‌بندی‌های پایه ضمن برخورداری از کارایی قابل قبول، با یکدیگر متفاوت بوده و قاعدة ترکیبی مناسبی برای تلفیق نتایج آنها به کار گرفته شود (Kabir, 1384). با توجه به نتایج جدول (۶)، می‌توان ادعا کرد هریک از دسته‌بندی‌ها به تنهایی نتیجه قابل قبولی دارد، همچنین این دسته‌بندی‌ها در دسته‌های متفاوت، دقتشاکری متفاوتی دارند. در نتیجه دو شرط را دارند و باید به دنبال قاعدة ترکیبی مناسب بود.

در روش‌های دسته‌بندی، به‌الزام افزایش ویژگی‌ها با افزایش دقت همراه نیست و گاهی مواردی پیش می‌آید که با افزایش تعداد ویژگی‌ها، دقت بهشت کاهش می‌یابد. در دسته‌بند SRC با اضافه کردن بعضی ویژگی دقت بهشت کاهش می‌یابد. این مورد در ویژگی UNIGRAMS به‌وضوح مشخص است به جهت استفاده از ویژگی‌های مناسب، جهت دست‌یافتن به دقت بیشتر، هر مجموعه از ویژگی‌ها با دسته‌بندی‌های متفاوت مورد استفاده قرار گرفته است تا ضمن دست‌یابی به دقت‌های بالا در دسته‌های متفاوت بتوان با یک روش ترکیبی مناسب دقت کلی را افزایش داد.

همان‌طور که اشاره شد، برچسب نهایی هر پرسش از ترکیب خروجی سه دسته‌بند ایجاد می‌شود، برای این منظور با توجه به این که دسته‌بندی‌های مورد استفاده از نوع تک طبقه است. نتایج هر یک از دسته‌بندی‌ها را توسط روش‌های ترکیبی تک‌طبقه ترکیب می‌کنیم، روش‌های رأی‌گیری وزن‌دار، فضای دانش رفتار، بیز ساده، کلیشه تصمیم و دمپستر شفر.

در روش رأی‌گیری وزن‌دار، نیاز است برای هر دسته وزنی تعلق گیرد، وزنی به عنوان ضریب اطمینان. در این جا برای هر دسته‌بند، وزن تعلق‌گرفته یک، بردار شش‌تایی است که همان صحت هر دسته‌بند برای شش دسته موجود است. در روش فضای دانش رفتار با ثبت نظرات دسته‌بندی‌ها در مورد الگوهایی که طبقه آنها معلوم است، رفتار جمعی دسته‌بندی‌ها را مدل کرده و بر اساس این مدل برچسب طبقه‌ای الگوی ناشناخته X را مشخص می‌کند. به عبارت دیگر در این روش، تصمیم‌گیری نهایی برای طبقه یک الگو با استفاده از رفتاری که دسته‌بندی‌های مختلف در هنگام یادگیری الگوها از خود نشان داده‌اند صورت می‌گیرد. در این روش باید تمامی حالات ممکن در نظر گرفته شود. در اینجا حالات ممکن $6 \times 6 = 36$ می‌باشد و برای هر یک از حالات در



- [5] T.K. Ho, J.J. Hull, and S.N. Srihari, "Combination of decisions by multiple classifiers." In Structured document image analysis, Springer Berlin Heidelberg 1992, pp. 188-202.
- [6] Hoque, M. Moinul, T. Goncalves, and P. Quaresma, "Classifying Questions in Question Answering System Using Finite State Machines with a Simple Learning Approach." In *PACLIC* Vol. 27, Taiwan 2013 pp. 409-414.
- [7] Z. Huang, M. Thint, and Z. Qin, "Question classification using head words and their hypernyms." In Association for Computational Linguistics: Proceedings Conference on Empirical Methods in Natural Language Processing, Hawaii USA: ACL 2008, pp. 927-936.
- [8] V. Krishnan, Das. Sujatha, and S. Chakrabarti, "Enhanced answer type inference from questions using sequential models." In Association for Computational Linguistics: Proceedings Conference on Empirical Methods in Natural Language Processing, Vancouver Canada: ACL 2005, pp. 315-322.
- [9] Kuncheva, I. Ludmila, Combining pattern classifiers: methods and algorithms. John Wiley & Sons, 2004.
- [10] Li, Xin, and D. Roth, "Learning question classifiers." In Association for Computational Linguistics: COLING '02 Proceedings of the 19th international conference on Computational linguistics, Taipei, Taiwan: COLING 2002, pp. 1-7.
- [11] B. Loni, S. H. Khoshnevis, and P. Wiggers, "Latent semantic analysis for question classification with neural networks." In Automatic Speech Recognition and Understanding, Hilton Waikoloa: ASRU, 2011, pp. 437-447.
- [12] M. C. Marneffe, B. MacCartney, and D. Christopher, "Generating typed dependency parses from phrase structure parses." In Conferences bring together a large number of people working and interested in HLT Proceedings: LREC, Genoa, Italy: May 2006, pp. 449-454.
- [13] A. Merkel, and D. Klakow, "Improved methods for language model based question classification." In INTERSPEECH, Antwerp, Belgium :August 2007, pp. 322-325.
- [14] D. Moldovan, M. Pașca, S. Harabagiu, & M. Surdeanu, "Performance issues and error analysis in an open-domain question answering system." ACM Transactions on Information Systems, vol. 21, pp. 133-154, October 2003.
- [15] Y. Pan, Y. Tang, L. Lin, & Y. Luo, "Question classification with semantic tree kernel." In ACM SIGIR conference on Research and development in information retrieval: Proceedings of the 31st annual international, Singapore, Singapore, July 2008, pp. 837-838.
- [16] D. Radev, W. Fan, H. Qi, H. Wu, & A.Grewal, "Probabilistic question answering on the

موقعی که دسته‌بند مبتنی بر ماشین بردار پشتیبان نتیجه قابل قبولی ندارد، سایر دسته‌بندها نتیجه بهتری دارند.

روش‌های مورد استفاده در این مقاله برای ترکیب دسته‌بندها، تعیین برچسب نهایی براساس رفتار گذشته دسته‌بندها است. در واقع وضعیت کنونی داده در دسته‌بندها در نظر گرفته نمی‌شود. می‌توان با استفاده از دسته‌بندهای احتمالی مثل بیز و یا تبدیل دسته‌بند مبتنی بر ماشین بردار پشتیبان به صورت احتمالی بدین صورت که برای هر داده براساس امتیاز داده شده برای تعلق به هر طبقه وضعیت کنونی داده را در برچسب نهایی دخیل داد؛ علاوه بر این برای دسته‌بندهای مورد استفاده در این مقاله از ویژگی‌های لغوی و نحوی استفاده شده است که می‌توان با استفاده از ویژگی‌های معنایی مثل زیرشمول‌ها یا مترادفات مربوط به کلمه اصلی دقت عملیات دسته‌بندی را افزایش داد. همچنین در این مقاله برای دسته‌بندی مبتنی بر یادگیری از کرنل خطی استفاده شده است. با توجه به کارهای انجام شده، به‌ویژه برای دسته‌بندی مبتنی بر نمایش پراکنده و نتایج آنها، با استفاده از کرنل‌های دیگر مثل گوسی می‌تواند به نتایج بهتری دست یافت.

۶- مراجع

نبوی کریزی، سیدحسن، کبیر، احسان الله، "ترکیب طبقه بندها :ایجاد گوناگونی و قواعد ترکیب"، نشریه علمی پژوهشی انجمن کامپیوترا ایران مجلد ۳، شماره ۳ (الف)، صفحه ۹۵. پائیز ۱۳۸۴.

- [1] S.H. Nabavi karizi, & E. Kabir, "Combining classifiers: Diversifying and rules of composition." CSI Journal on Computer Science and Engineering, vol. 3, pp. 95. Autumn 1384
- [2] M. Collins, "Head-driven statistical models for natural language parsing." Computational linguistics, vol. 29, pp. 589-637, Dec 2003.
- [3] J.R. Finkel, T. Grenager, and C. Manning, "Incorporating non-local information into information extraction systems by gibbs sampling," In Association for Computational Linguistics: Proceedings of the 43rd annual meeting on association for computational linguistics, Michigan: ACL, 2005. pp. 363-370.
- [4] Ulf. Hermjakob, "Parsing and question classification for question answering," In Association for Computational Linguistics: Proceedings of the workshop on Open-domain question answering, Vol. 12, France: ACL, 2001, pp. 1-6.



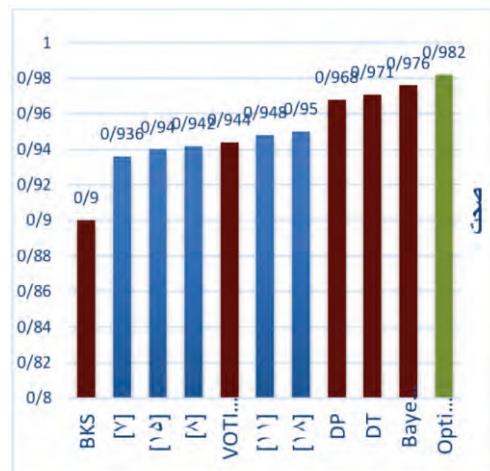
دسته‌بند، داده را با طبقه‌ای متفاوت برچسب‌گذاری کند میزان شباهت بردار داده برای هر یک از طبقه‌ها مشابه هم بوده و احتمال بروز خطا در انتخاب برچسب نهایی افزایش می‌یابد.

در روش ترکیبی ارائه شده، برچسب نهایی براساس رفتار گذشته دسته‌بندها مشخص می‌شود و وضعیت داده در دسته‌بندها در نظر گرفته نمی‌شود؛ این در حالی است که ممکن است برچسب‌دهی با اشتباه همراه باشد. به عنوان مثال برچسب تعلق گرفته برای پرسش ۶ توسط دسته‌بند مبتنی بر قانون و مبتنی بر نمایش پراکنده DESC و برچسب تعلق گرفته توسط دسته‌بند مبتنی بر ماشین بردار پشتیبان LOC است. در روش‌های ترکیبی برچسب تعلق گرفته برای این پرسش DESC است که این برچسب به اشتباه داده شده است. در SVM متلب برچسب داده شده توسطتابع نشانه^۱ در آخرین مرحله مشخص می‌شود. در واقع برای مقادیر کم و زیاد به یک صورت برخورد می‌کند و یک بر جسب تعیین می‌شود. این در صورتی است که برای داده‌های با مقدار زیاد می‌توان با اطمینان بیشتری برخورد کرد. در این مثال با توجه به اینکه مقدار داده شده توسط SVM مقداری زیادی است پس می‌توان به برچسب داده شده توسط SVM اطمینان بیشتری داشت.

۵- نتیجه‌گیری و کارهای آینده

هدف از سامانه‌های پرسش‌وپاسخ، پاسخ‌دهی خودکار به پرسش‌های زبان طبیعی است که توسط انسان پرسیده می‌شود. در این سامانه‌ها دسته‌بندی پرسش‌ها نقشی مهم در انتخاب پاسخ صحیح برای پرسش داده شده دارد. در این مقاله یک روش ترکیبی جدید برای دسته‌بندی پرسش ارائه شده است. در روش ترکیبی از یک دسته‌بند مبتنی بر قانون و دو دسته‌بند مبتنی بر یادگیری استفاده شده است. برای دسته‌بند مبتنی بر قانون از یک مجموعه قانون در قالب عبارات منظم استفاده شده است؛ و برای دسته‌بندهای مبتنی بر یادگیری عملیات دسته‌بندی براساس ویژگی‌های لغوی و نحوی پرسش‌ها انجام می‌گیرد. برای ترکیب نتایج دسته‌بندی از روش‌های رأی‌گیری، بیز ساده و فضای دانش رفتار استفاده شده است که با روش ترکیبی بیز ساده بهترین نتیجه حاصل شد. کسب نتیجه خوب در روش ترکیبی، به دلیل رفتار متفاوت دسته‌بندها در روش‌های مختلف است. یعنی در

با توجه به نتایج حاصل از شکل ۵ نتایج حاصل از ترکیب دسته‌بندها به روش بیز ساده بهترین نتیجه را به همراه دارد. همچنین در طبقه‌بند فرضی بهینه دقیق ۹۸۲٪ است که نشان‌دهنده این است که در بهترین روش ترکیبی مورد استفاده که بیز ساده است، به اندازه ۰،۰۶٪ خطا وجود دارد؛ چون که طبقه‌بند فرضی بهینه تنها زمانی اشتباه می‌کند که همه طبقه‌بندهای پایه اشتباه کنند. پس این اختلاف بیان‌کننده این نکته است که حداقل یکی از دسته‌بندها عملیات برچسب‌گذاری را به درستی انجام داده است؛ اما در ترکیب نتایج سامانه دچار اشکال شده است. در روش ترکیبی فضای دانش رفتار علت پایین‌بودن نتیجه وجود حالت‌های بدون نتیجه است. حالت‌هایی که در مرحله آزمون رخ می‌دهند، اما در مرحله یادگیری همچنین حالتی رخ نمی‌دهد، رسیدن به نتیجه مطلوب با این روش نیازمند داده‌های آموزشی کافی یا وجود حالت‌های محدود است.



(شکل-۵): امتیاز نهایی سیستم و سیستم‌های موجود

(Figure-5): The final score from the proposed method and the other existing approaches

روش ترکیب وزن دار تنها به وضعیت همان داده وابسته است. چالش اصلی این روش ترکیبی در حالتی است که تعداد بیشتری از دسته‌بندها به اشتباه یک طبقه را انتخاب کنند که سبب اشتباه در برچسب‌گذاری نهایی می‌شود.

درستی روش‌های کلیشه تضمیم و تئوری دمپستر شفر وابسته به وضعیت داده‌های مرحله آزمون است و برای طبقه‌های با تعداد داده کمتر احتمال بروز خطا بیشتر است. علاوه بر این در این دو روش در حالت‌هایی که هر یک از سه

¹ sign

web,” Journal of the American Society for Information Science and Technology, vol. 56, pp. 571-583, DEC 2005.

- [17] S. K. Ray, S. Singh, & B. P. Joshi, “A semantic approach for question classification using WordNet and Wikipedia.” Pattern Recognition Letters, vol. 31, pp. 1935-1943, October 2010.
- [18] J. Silva, L. Coheur, A. C. Mendes, & A. Wichert, “From symbolic to sub-symbolic information in question classification.” Artificial Intelligence Review, vol. 35, pp. 137-154, February 2011.
- [19] H. Sundblad, “Question classification in question answering systems”. Phd dissertation., Institutionen för datavetenskap, 2007.
- [20] K. Toutanova, D. Klein, C.D. Manning, & Y. Singer, “Feature-rich part-of-speech tagging with a cyclic dependency network”. In Association for Computational Linguistics on Human Language Technology: Proceedings of the Conference of the North American Chapter, Washington, DC, USA, October 2003, pp. 173-180.
- [21] J. Wright, et al. “Robust face recognition via sparse representation.” IEEE transactions on pattern analysis and machine intelligence, vol 31, pp. 210-227, Feb 2009.



هادی قائمی مدرک کارشناسی ارشد خود را در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه فردوسی مشهد اخذ کرده است. زمینه پژوهشی مورد علاقه ایشان شامل پردازش زبان طبیعی و پردازش الگو است.
نشانی رایانماء ایشان عبارت است از:

Hadi.qaemi@stu.um.ac.ir



محسن کاهانی استاد گروه مهندسی کامپیوتر دانشگاه فردوسی مشهد و مدیر آزمایشگاه فناوری وب است. ایشان دکتراخود را در رشته مهندسی کامپیوتر از دانشگاه ولونگونگ استرالیا در سال ۱۳۷۷ اخذ کرده است. زمینه پژوهشی مورد علاقه ایشان شامل وب معنایی، پردازش زبان طبیعی، سیستم‌های تصمیم‌یار و مهندسی نرم‌افزار است.
نشانی رایانماء ایشان عبارت است از:

kahani@um.ac.ir

