

ارائه‌ی یک روش به منظور تکمیل پایگاه‌های دانش با استفاده از سیستم‌های پرسش‌وپاسخ

عاطفه صافدل^۱، سید مصطفی فخرالحمد^۲، محمدهدادی صدرالدینی^۳

^۱دانشجوی کارشناسی ارشد، دانشکده مهندسی برق و کامپیوت، دانشگاه شیراز، شیراز
a.safdel@cse.shirazu.ac.ir

^۲استادیار، دانشکده مهندسی برق و کامپیوت، دانشگاه شیراز، شیراز
fakhrahmad@shirazu.ac.ir

^۳استاد، دانشکده مهندسی برق و کامپیوت، دانشگاه شیراز، شیراز
sadredin@shirazu.ac.ir

چکیده

مدت‌هاست که پایگاه‌های دانش به عنوان منابع مهمی برای دسترسی به اطلاعات ساختاریافته مورد جستجو قرار می‌گیرند. از جمله کاربردهای آن‌ها می‌توان به سیستم‌های پرسش‌وپاسخ اشاره کرد؛ آن‌هایی که در جستجوی پاسخ پرسش‌ها تنها در قالب فواین ساختاریافته‌ی سه‌تایی هستند. با وجود کاربردهای زیادی که پایگاه‌های دانش دارند، حتی بزرگ‌ترین نمونه‌های موجود از آن‌ها به صورت وسیعی ناقص هستند و احتمال اینکه به آن‌ها مراجعه شود و پاسخ لازم یافت نشود زیاد است. به عنوان مثال اطلاعات مربوط به همسر و فرزندان اشخاصی که در Freebase ذخیره شده‌اند، به ترتیب برای ۹۲ درصد و ۹۴ درصد افراد وجود ندارد. در این پژوهش سعی شده است راهکاری برای اضافه کردن سه‌تایی‌های جدید به پایگاه‌های دانش ارائه شود که استخراج مقادیر مجهول را بر مبنای سیستم‌های پرسش‌وپاسخ انجام دهد و نگاشت پاسخ‌های استخراج شده به موجودیت‌ها را بر مبنای ماهیت رابطه‌ی مورد بررسی و سایر روابط موجود در پایگاه دانش به انجام برساند. برای ارزیابی روش پیشنهادی، نمونه‌گیری از بین صدهزار شخص مهم و برجسته‌ی جهان انجام گرفته و نتیجه‌ی ارزیابی، بهبود و تبیین پاسخ‌های صحیح در قالب معیارهای MRR و MAP می‌باشد.

کلمات کلیدی

پایگاه‌دانش، استخراج متن، نگاشت موجودیت، تکمیل اطلاعات، Freebase

و جستجو در آن‌ها پسیارکم بود. پس از آن، مسائل موجود در دنیای واقعی به صورت داده در پایگاه‌های داده ذخیره می‌شدند. هرچند می‌توان برای داده‌ها در پایگاه‌های داده، ویژگی‌هایی تعریف کرد و از این طریق امکان تزدیکی اطلاعات ذخیره شده را به واقعیت بیشتر کرد؛ اما باز هم شرایطی پیش می‌آید

۱- مقدمه

از گذشته‌ها مسئله‌ی ذخیره‌سازی مطرح است و پیش همواره به دنبال نگه‌داری اطلاعات بوده است. ابتدا از فایل‌ها استفاده می‌شد که قابلیت مدیریت، پردازش

۲- شرح مسئله

به دلیل افزایش مراجعه به پایگاه‌های دانش به عنوان یک منبع اطلاعاتی، اهمیت زیادی دارد که اطلاعات موجود در آن کامل باشد. تکمیل بودن اطلاعات لزوماً به معنی وجود همه‌ی اثواب ممکن از موجودیت‌ها و یا وجود همه‌ی نمونه‌های هر نوع موجودیت نیست. بلکه این اهمیت دارد که روابط متداولی که بین انواع موجودیت‌ها اغلب برقرار است، نیز تا آن جا که ممکن است کامل باشد، به عنوان مثال فرض کنید که از یک سیستم پرسش‌پاسخ مبتنی بر پایگاه‌دانش پرسیده می‌شود که «تویینده‌ی مثنوی معنوی چه کسی است؟» از آن جایی که در این حالت پایگاه‌دانش برای یافتن پاسخ جستجو می‌شود، برای پاسخ‌گویی به این پرسش، باید هر دو موجودیت‌های «مولانا» و «مثنوی معنوی» در پایگاه‌دانش وجود داشته باشند و مهم‌تر از همه، لینک مستقیم یا غیرمستقیم بین آن‌ها تشکیل شده باشد تا «مولانا» به عنوان خروجی جستجو در پایگاه‌دانش پرگشت داده شود. با اینکه پایگاه‌های دانش پسیار غنی و عظیمی وجود دارند، باز هم کمبود اطلاعاتی شدیدی در آن‌ها وجود دارد که باعث می‌شود در پسیاری از موارد، رجوع به آن‌ها بدون نتیجه باشد. بنابراین همواره سعی بر این است که پایگاه‌های دانش را کامل‌تر کرد و قوانین جدیدی به آن اضافه نمود.

یکی از انواع اطلاعاتی که مردم علاقه‌مند به جستجوی آن‌ها هستند و پایگاه‌های دانش باید در این زمینه نیز غنی باشند، قوانینی است که درباره‌ی «اشخاص» است. این اشخاص می‌توانند آن قدر معروف باشند که به دلیل شهرت و علاقه‌ی مردم به پیشتر دانستن درباره‌ی آن‌ها، مرتب مورد پرسش قرار بگیرند. به عنوان مثال راجع به محل تولد، همسر، فرزندان، شغل و حرفه، ملیت و تحصیلات آن‌ها به شکل متناوب پرسش‌های مطرح شود. بنابراین پایگاه‌دانش هم باید آن اشخاص را به عنوان موجودیت داشته باشد و هم اینکه رابطه‌های ذکر شده، بین آن‌ها و موجودیت‌های دیگر وجود داشته باشد تا پرسش‌ها به پاسخ برسد و درصد پاسخ‌گویی سیستم بالا برود.

اگر مسئله‌ی اضافه کردن اشخاص جدید به پایگاه‌دانش دغدغه‌ی اصلی نباشد و فقط بخواهیم اشخاص موجود در آن را درباره‌ی این روابط کامل کنیم، با آماری از نقص اطلاعات درباره‌ی رابطه‌های «همسر» و «فرزندان» در Freebase رویه‌رو هستیم که در جدول (۱) نشان داده است. اطلاعات این جدول از [9] استخراج شده است.

آماری که جدول (۱) نشان می‌دهد، درباره‌ی شدت نقص اطلاعات برای همه‌ی ۳ میلیون شخصی است که به صورت موجودیت در Freebase وجود دارند. به صورتی که حتی ۹۴ درصد از آن‌ها در رابطه‌ی «فرزندان» شرک نداشته‌اند. شاید این مسئله مطرح شود که وجود چنین قوانینی در پایگاه‌دانش برای همه‌ی این ۳ میلیون شخص اهمیت ندارد و اگر تنها درمورد افرادی که زیاد مورد جستجو قرار می‌گیرند، غنی باشد، کفايت می‌کند. همان‌طور که از اطلاعات موجود در ستون دیگر جدول مشخص است، این مشکل درباره‌ی آن‌ها کم‌تر است ولی همچنان به شکل وسیعی وجود دارد. آمار موجود در این ستون برای ۱۰۰ هزار فردی است که بیشترین جستجو درباره‌ی آن‌ها در سطح وب صورت گرفته است. شدت ناکامل بودن Freebase در حوزه‌ی رابطه‌های اساسی «اشخاص» باعث می‌شود که رفع این نقص اهمیت پیدا کند.

اقای West و همکاران [9] راهکاری برای تکمیل اطلاعات موجود در Freebase ارائه دادند که سیستم جدید طراحی شده را با آن مقایسه می‌کنیم.

که در آن شرایط، این شیوه‌ی ذخیره‌سازی کافی نیست. زمانی که ارتباط موجود بین داده‌ها ارزشمند باشد، باید به طریقی بین داده‌ها لینک برقرار کرد و لینک‌ها را نیز ذخیره نمود. پایگاه‌های دانش می‌توانند پاسخ‌گوی این مشکل باشند. بنابراین نباید پایگاه‌های داده را با پایگاه‌های دانش اشتباه گرفت.

یک پایگاه‌دانش با هدف نگهداری موجودیت‌ها و مخصوص بودن رابطه‌ی بین موجودیت‌ها تشکیل می‌شود. پایگاه‌دانش می‌تواند به این منظور، از یک یا چند پایگاه‌داده استفاده کند. اطلاعات ذخیره‌شده در هر پایگاه‌دانش اغلب دارای اشتراکاتی هستند و مربوط به موضوع خاصی می‌شوند.

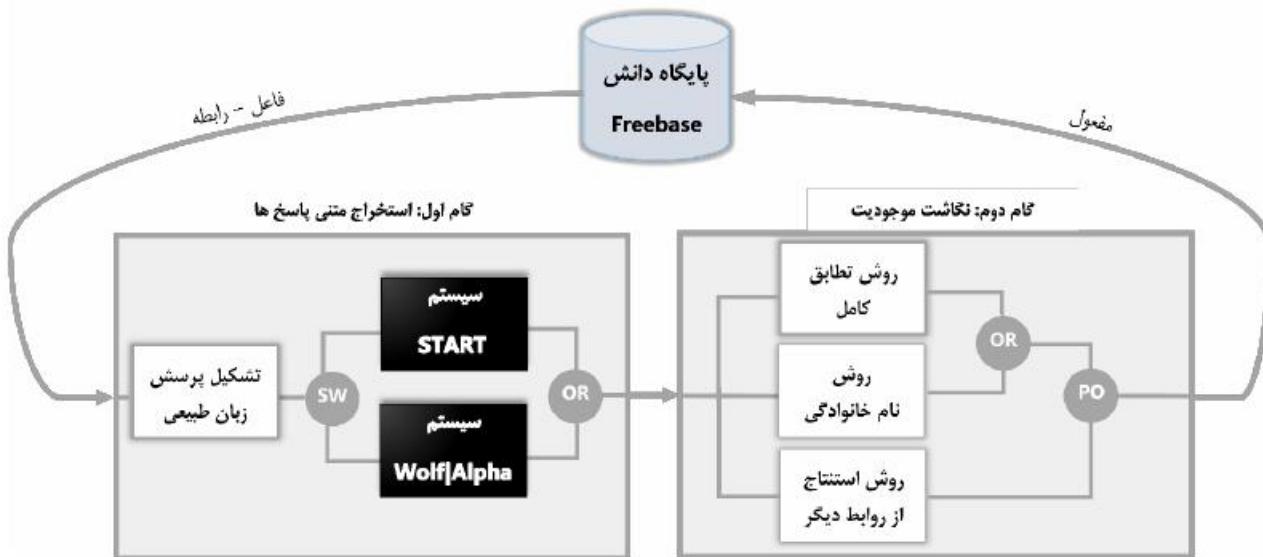
با رویکردی دیگر، مسئله‌ی بازیابی اطلاعات ذخیره‌شده مطرح است. اگر داده‌ها بدون هیچ‌گونه ساختارمندی و به صورت متنی ذخیره شوند، فرایند بازیابی آن‌ها مشکل خواهد بود و اگر به جستجوی کلمه‌ای در آن متن پرداخته شود، حداقل نیازمند تجزیه‌ی لغوی^۱ متن می‌باشد. بنابراین با گذرا زمان به سوی داده‌های ساختارمند و نیمه‌ساختارمند روی آورده شد. در این نوع از پایگاه‌دانش، داده با فرمت خاصی ذخیره می‌شود. به عنوان مثال فرمت RDF^۲ به طور متدالوی مورد استفاده قرار می‌گیرد. این فرمت نمایش داده دارای سه قسمت اطلاعاتی است که عنصر اول و سوم موجودیت‌هایی هستند که از طریق اطلاعاتی که عنصر دوم آن را نمایش می‌دهد، بهم مربوط می‌شوند. با ساختارمند شدن پایگاه‌های دانش، شیوه‌ی جستجو در آن‌ها و بازیابی اطلاعات از آن‌ها هم ساده‌تر می‌شود. این فرمت داده به درک بهتر اطلاعات کمک می‌کند و می‌توان پرسچو^۳های دقیقی روى آن‌ها اعمال کرد.

اطلاعاتی که در پایگاه‌های دانش ساختارمند ذخیره می‌شوند، ممکن است به صورت اتوماتیک از متون ساده استخراج شده و یا اینکه به صورت دستی و توسط افراد وارد شده باشند. مسلماً دقت پایگاه‌های دانش با استخراج خودکار اطلاعات کمتر از حالت دیگر است؛ اما هر دو روش هنوز متدالوی هستند. از جمله نمونه‌هایی که از پایگاه‌های دانش موجود می‌شوند، ممکن است به SigmaKB^۴ می‌شود. برخی از آن‌ها مانند Freebase^۵ بسیار بزرگ هستند و شامل موجودیت‌ها و روابط بسیار زیادی می‌شوند. هرچند که به دلیل افزایش روزافزون اطلاعات متنی، حتی پایگاه‌های دانش بزرگ نیز، از ابعاد مهمی ناقص هستند.

موتورهای جستجو^۶ قابلیت‌های معنایی خوبی در اختیار می‌گذارند. اگر از جوامع به اشتراک‌گذاری دانش^۷ مثُل ویکی‌پدیا استفاده شود، فرایند «استخراج موجودیت‌ها و روابط» از متان و ب نیمه‌ساختارمند، به خوبی متان زبان طبیعی می‌تواند به طور خودکار صورت گیرد. کارهایی نیز از این نوع انجام شده است؛ مانند DBpedia^۸، EntityCube^۹ و KnowItAll^{۱۰}. هدف همه این است که یک پایگاه‌دانش جامع از قوانین^{۱۱} درباره‌ی موجودیت‌های نامدار، دسته‌های معنایی آن‌ها، ارتباط‌های متقابل آن‌ها وجود داشته باشد.

جدول (۱) : درصد عدم وجود اطلاعات درباره‌ی اشخاص ذخیره شده در Freebase در رابطه‌های همسر و فرزندان

اطلاعات ناقص (%)		رابطه
کل اشخاص	صفه‌های نظر برتر	
%۹۲	%۶۸	همسر
%۹۴	%۸۰	فرزندان



شکل (۱) : شیمای کلی سیستم طراحی شده به منظور تکمیل اطلاعات ناقص.

SW: ورودی را به یک از خروجی‌ها می‌فرستد.

OR: همه‌ی ورودی‌ها را به خروجی می‌فرستند.

PO: نتیجتاً ورودی مربوط به "استنتاج از روابط دیگر" به خروجی می‌رود. در صورت خالی بودن آن ورودی، ورودی دیگر به خروجی می‌رود.

است؛ اما حل این مشکل مربوط به گام بعدی می‌شود. در پژوهش انجام شده از روش مبتنی بر پرسش از سیستم‌های پرسش‌پاسخ استفاده شده است. این-گونه سیستم‌ها معمولاً پاسخ را به صورت دقیق‌تر، مشخص‌تر و مختص‌تر نسبت به سیستم‌های بازیابی اطلاعات (موتورهای جستجو) برمی‌گردانند. آن-ها قابلیت دریافت پرسش‌های زبان طبیعی را داشته و ممکن است برای اعلام پاسخ، منابع مختلفی را جستجو کنند. این منابع ممکن است پایگاه‌های دانش مخصوص به خودشان، چندین سند متنی، اینترنت و یا ... باشد.

در روش مبتنی بر پرسش از این سیستم‌ها، می‌توان فاعل و رابطه را در قالب پرسش‌های زبان طبیعی درآورد و آن‌ها را از سیستم پرسید؛ با این امید که مفهول موردنظر در قالب پاسخ برگردانده شود. بنابراین باید با داشتن الگوی مناسب برای طرح پرسش از آن‌ها به گرفتن پاسخ موردنظر امیدوار بود. سیستم‌های پرسش‌پاسخی که در این پژوهش به صورت black-box مورد استفاده قرار گرفته‌اند، سیستم‌های پرسش‌پاسخ START [10,11] و STARD [12] Wolfram|Alpha هستند.

START اولین سیستم پرسش‌پاسخ مبتنی بر وب در سطح جهان است و برای دریافت پاسخ سوالات منابع مختلفی را در سطح وب جستجو می‌کند. همچنین ممکن است از پایگاه‌دانش خود برای پاسخ‌دهی استفاده کند. این سیستم پرسش‌پاسخ در دانشگاه MIT طراحی و پیاده‌سازی شده و از سال ۱۹۹۳ به صورت آنلاین در دسترس است. این سیستم در بسیاری از زمینه‌ها پاسخ‌گو است. زمینه‌هایی مثل مکان‌ها، نقشه‌ها، سیستم‌های اقتصادی و سیاسی، آباده‌ها، فیلم‌ها، بازیگران، افراد، زندگی‌نامه، تعاریف بر طبق لغت-نامه‌ها و

Wolfram|Alpha یک موتور دانش است که قابلیت انجام محاسبات و تحلیل را دارد و می‌تواند در زمینه‌های کاملاً متفاوتی پاسخ‌گو باشد؛ از جمله: مهندسی، شیمی، ریاضی، موزیک، تحصیل، هنر سلامت و این سیستم برای پاسخ‌دهی، پایگاه‌دانش مخصوص به خود را جستجو می‌کند و در صورت

۳- روش پیشنهادی

مسئله به این صورت است که یک فاعل و یک رابطه با شناسه‌ی مشخص داریم و می‌خواهیم مفعول آن را بیابیم. به صورتی که سیستم، شناسه‌ی یک مفعول در پایگاه‌دانش را به عنوان مفعول برگرداند. این مسئله می‌تواند به صورت چند جوابی هم وجود داشته باشد. از منظور دیگر، گاهی لازم است چندین جواب محتمل به صورت فهرست ارائه شود و تصمیم نهایی برای اضافه کردن آن قاتون به پایگاه‌دانش، توسط بخش دیگری گرفته شود. به این ترتیب، در این پژوهش مانند پاسخ‌های نهایی را تبیین نموده ارائه می‌دهیم. نمای کلی از سیستم طراحی شده، در شکل (۱) آمده است. همان‌طور که در شکل مشخص است، فاعل و رابطه‌ی موردنظر وارد سیستم می‌شوند. سه‌سهم قطعه‌های متنی محتمل به عنوان مفعول در مرحله‌ی اول حبس زده می‌شوند. در مرحله‌ی بعد، سیستم مشخص می‌کند این قطعات متنی اشاره به کدام‌یک از موجودیت‌ها در پایگاه‌دانش می‌کنند.

در ادامه جزئیات هریک از مراحل را شرح می‌دهیم.

۱- گام اول: استخراج متنی پاسخ‌ها

در گام اول باید برای یک فاعل و رابطه‌ی مشخص، مفعول آن پیش‌بینی شود. این پیش‌بینی فقط به صورت متنی است و لازم نیست مشخص شود که مفعول دقیقاً معادل با کدام‌یک از موجودیت‌ها در پایگاه‌دانش می‌باشد. به عنوان مثال، اگر فاعل «حافظا» و رابطه‌ی موردنظر « محل‌ولد » باشد، در این گام باید تعدادی جواب به صورت متنی حبس زده شود و در صورتی که «شیراز» در فهرست جواب‌ها باشد، این مرحله کار خود به خوبی انجام داده است. این در حالی است که ممکن است چندین «شیراز» در پایگاه‌دانش وجود داشته باشد و دقیقاً مشخص نباشد که کدام‌یک از این «شیراز»‌ها موردنظر

آنها را با هم اشتباه گرفت. دلیل دیگری که می‌تواند عملکرد نگاشت را مشکل کند، عدم استفاده از یک متن کمکی برای رفع ابهام می‌باشد. در روش‌های معمول برای نگاشت از یک متن کمکی هم استفاده می‌شود تا این نگاشت اشتباه رخ ندهد. معمولاً متن اطلاعات جانبی راجع به فاعل وجود دارد و از طریق روش‌های پردازش زبان طبیعی سعی می‌شود نزدیک‌ترین موجودیت کاندیدا در پایگاه‌دانش را به عنوان مفعول درنظر گرفت. اما در روش استفاده شده در طراحی این سیستم، فرض شده که هیچ متن کمکی وجود ندارد و با این فرض کارایی سیستم در بدترین شرایط اطلاعاتی تخمین زده شده است. به این دلیل که این شرایط بسیار محتمل است که حتی اگر به عنوان مثال متنی هم در اختیار باشد، در آن متن پارامترهایی که کمک کننده برای نگاشت هستند موجود نیست. این مسئله حداقل در حوزه‌ی تعریف شده برای این پژوهش زیاد رخ می‌دهد. اشخاص مشهوری را فرض کنید که اطلاعات متنی که از آن‌ها در صفحات موجود است اغلب پیامون همان دلیل شهرت‌شان است. مثلاً صفحه‌ی یک بازیگر پیشتر پیشنهاد هنری وی را پوشش می‌دهد تا اینکه به تشریح زندگی شخصی اش پردازد و زندگی شخصی وی را به صورت مختصر شرح می‌دهد. همین مسئله باعث می‌شود زمانی که به دنبال اطلاعات شخصی افراد هستیم، آن صفحه برای رفع ابهام از اطلاعات شخصی کارا نباشد. البته این اختصار در اطلاعات در همه‌ی موارد رخ نمی‌دهد اما به دلایلی که ذکر شد، در این پژوهش فرض را بر این نگاشتیم که در همه‌ی حالات از متن کمکی بهره نگیرید. موضوع دیگری که نگاشت متن به موجودیت در این سیستم با آن مواجه است، نتیجه‌ی پذیرش هر قطعه‌ی متنی کوچک اطلاعاتی است که از مرحله‌ی فرآیند، قبل به این جا رسیده است. در مرحله‌ی استخراج متنی پاسخ‌ها، هر متن کوچکی را پذیرفته و از این مرحله می‌خواهیم تا جایی که ممکن است معادل‌هایی برای مان بیابد و آن‌ها را دور نریزد؛ در حالی که در روش‌های متدالوچن نیست. صفحه‌ی فوتیالیستی را در ویکی‌پدیا فرض کنید که کاملاً درباره‌ی زندگی حرفاًی وی می‌باشد و تنها چیزی که درباره‌ی فرزندان و همسر او گفته نام کوچک آن‌ها است. سیستم طراحی شده سعی می‌کند از همین اطلاعات کم هم برای نگاشت استفاده کند و آن‌ها را اطلاعات بی ارزش نخواند و کثار نزند.

زمانی که سیستم در جستجوی «همسر» یا «فرزندان» شخصی است، «اشخاص» موجود در پایگاه‌دانش را بررسی می‌کند که آیا حالت‌هایی که در ادامه شرح داده شده برای آن‌ها صادق است یا خیر. اگر روش‌های ذکر شده نتیجه‌دهند، تعدادی موجودیت از بین «اشخاص» را خواهیم داشت که کاندیدای مفعول بودن هستند.

۱-۲-۳- روش مبتنی بر استخراج از روابط موجود دیگر

در این روش سیستم از روابط دیگر موجود در پایگاه‌دانش برای یافتن موجودیت موردنظر استفاده می‌کند. برای این منظور ارتباط‌های خانوادگی، فاعل و قطعات متن دریافتی کاندیدا استفاده می‌شوند. درصورتی که سیستم بتواند از این طریق موجودیت‌ها را بیابد که همان به عنوان پاسخ برگشت داده می‌شود؛ در غیر این صورت هردو روشنی که در ادامه آمده‌اند، اجرا می‌شوند.

۲-۳- روش تطابق کامل

اگر در پایگاه‌دانش دقیقاً یک شخص وجود داشته باشد که قطعه‌ی پاسخ متنی با نام وی برابر باشد، آن موجودیت به مجموعه‌ی پاسخ‌ها اضافه می‌شود.

نیاز، تحلیل‌های انجام می‌دهد تا جواب نهایی را اعلام کند. از جمله مواردی که این سیستم قادر به پاسخ‌گویی در آن زمینه است، افراد و تاریخچه‌ی آن-هاست. بنابراین درصورتی که دانش کافی درباره‌ی افراد در آن وجود داشته باشد، می‌تواند در نقش سیستم پرسش و پاسخ برای سیستم ما عمل کند.

در روش پیشنهادی برای تکمیل پایگاه‌دانش، این قابلیت وجود دارد که پرسش زبان طبیعی به یکی از این سیستم‌های پرسش و پاسخ ارسال می‌گردد و از عملکرد آن برای استخراج پاسخ استفاده می‌شود.

۳-۱-۱- استفاده از سیستم START

این سیستم به دلیل اینکه منابع ساختاریافته یا بدون ساختار مختلفی را در سطح وب جستجو می‌کند، ممکن است پاسخ را در قالب‌های متفاوتی نیز برگرداند. مثلاً پاراگرافی که جواب با احتمال زیادی در آن است و یا جواب دقیقی که در مقابل پرسنی نوشته شده است. این سیستم اگر به ابهام پرسد، همه‌ی حالت‌های ممکن را به عنوان پاسخ برمی‌گرداند. همچنین درصورتی که پاسخ را بداند، مشخص می‌کند که از چه منبعی این پاسخ را استخراج نموده است. وقتی که پرسش در رابطه با اشخاص باشد، اغلب به جستجوی آن‌ها در صفحات ویکی‌پدیا و IMDB^۱ می‌گردد و طبق شیوه‌ی ظاهری نام شخص مورد جستجو و کل افراد ذخیره شده در آن منابع، همه‌ی گزینه‌های محتمل را برمی‌گرداند.

سیستم ما هر زوج فاعل و رابطه را در قالب پرسش زبان طبیعی از START می‌پرسد. پاسخ‌های بدون منبع و بدون پرسنی بجهت دور می‌ریزد و بقیه‌ی جواب‌ها را که می‌تواند جداگانه‌های متفاوتی بین‌شان باشد، استخراج می‌کند.

۳-۱-۲- استفاده از سیستم Wolfram|Alpha

زمانی که پرسنی از این سیستم پرسیده می‌شود، پاسخ در result field نمایش داده می‌شود. درباره‌ی افراد و پرسن‌هایی که اطلاعات خاصی درباره‌ی آن‌ها را جستجو می‌کنند، پاسخ‌های Wolfram|Alpha به صورت دقیق هستند و نیاز به تحلیل خاصی ندارند. البته این به این معنا نیست که پاسخ‌هایی که مطمئن هستیم اشتباه هستند را دور نریزیم. زمانی که ظاهر پاسخ کاملاً نشان می‌دهد این یک پاسخ صحیح نیست، آن را دور نمی‌ریزیم. مثلاً در جستجوی یک اسم خاص بوده اینم، درحالی که سیستم پاسخی را برگرداند که با حرف بزرگ شروع نمی‌شود. حالت‌های دیگری که عدم پاسخ دهنده data not Wolfram|Alpha را نشان می‌دهد این است که عبارت «available» در فیلد نتایج داشته باشیم و یا اینکه این فیلد به طور کلی نمایش داده نشود. بنابراین سیستم ما هر زوج فاعل و رابطه را در قالب پرسش زبان طبیعی از سیستم Wolfram|Alpha می‌پرسد و از پاسخ آن به عنوان کاندیدای متنی مفعول استفاده می‌کند.

۳-۲- گام دوم: نگاشت موجودیت

تا این جا همه‌ی عملکرد سیستم پیامون یافتن نسخه‌ی متنی برای مقدار مفعول مجهول بود. در این قسمت نحوه‌ی نگاشت این مقدادر به موجودیت‌های پایگاه‌دانش شرح داده می‌شود.

نگاشت متن به موجودیت از چندین جنبه می‌تواند همراه با مشکلاتی باشد؛ از جمله آن موجودیت‌های نامداری که نام یکسان دارند اما خودشان یکسان نیستند. اشخاص زیادی سرتاسر دنیا می‌توانند نام مستعاری داشته باشند و نباید

جدول (۲) : مقایسه‌ی عملکرد سیستم طراحی شده با سیستم پیشین

روش	همسر		فرزندان	
	MRR	MAP	MRR	MAP
West	.۰۵۴	.۰۵۰	.۰۲۵	.۰۱۸
START	.۰۴۸	.۰۴۱	.۰۱۹	.۰۱۶
Wolfram Alpha	.۰۶۱	.۰۵۵	.۰۶۸	.۰۶۳

این فاعل‌ها طبق درجه اهمیت‌شان به ۱۰۰ دسته تقسیم شدند. سهی از هر دسته به صورت تصادفی ۱۰ نمونه انتخاب کردند که در نهایت ۱۰۰ نمونه از فاعل بهازای هر رابطه بدبست آمد. به این ترتیب سعی شد نزدیکترین داده با توجه به کار آقای West ایجاد شود تا این طریق امکان مقایسه با آن تا حدودی فراهم گردد؛ هرچند این مقایسه به صورت تقریبی باشد و دقیق نباشد. البته از آن جایی که مجموعه‌ای داده‌ی دیگری هم به همین روشن و با نمونه‌های تصادفی دیگری تشکیل شد و عملکرد سیستم در قالب معیارهای ارزیابی مشابه با عملکرد سیستم روی مجموعه‌ای داده‌ی اول مشاهده شد، این مستعلمه تواند نتایج دریافتی از سیستم را برای مقایسه با سیستم West اعتبار پیشتری بخشد.

۱- معیارها و نتایج ارزیابی

در این بخش، ابتدا کیفیت پاسخ‌ها را از نظر دقت رتبه‌بندی در چیدمان پاسخ‌های صحیح بررسی می‌کنیم. از آن جایی که هم تعداد پاسخ‌های صحیح اهمیت دارد و هم جایگاه آن‌ها در بین کل پاسخ‌های برگشته مهم است، از معیارهای MRR و MAP استفاده شده است. مقدار RR یک موجودیت در

یک لیست رتبه‌بندی شده برابر با مکوس رتبه‌ی بالاترین پاسخ صحیح است. وقتی که با چند لیست رتبه‌بندی شده روبرو باشیم و از RR آن‌ها میانگین بگیریم، به آن MRR گفته می‌شود. معیار MAP علاوه‌بر اینکه پاسخ صحیح اول در فهرست را درنظر می‌گیرد، رتبه‌ی همه‌ی پاسخ‌های صحیح را نیز به کار می‌برد. فرمول این دو معیار در [9] ذکر شده‌اند.

به ازای هریک از ۱۰۰ فاعلی که برای هر رابطه داریم یک لیست پاسخ رتبه‌بندی شده وجود دارد و طبق آن محاسبات لازم انجام شده است. برای ارزیابی، یک بار سیستم را با تنظیم سیستم پرسش‌وپاسخ START و بار دیگر با Wolfram|Alpha برای مرحله‌ی استخراج متنه پاسخ‌ها اجرا کردیم و عملکرد هریک را بررسی نمودیم. جدول (۲) و شکل‌های (۲) و (۳)،

شکل (۳) : عملکرد سیستم با توجه به معیار MAP



۳-۲-۳- روش نام خانوادگی

از آن جایی که در بسیاری از موارد، نام خانوادگی همسر و فرزندان یک فاعل با نام خانوادگی وی برابر است، اگر در پایگاه‌دانش شخصی داشته باشیم که نام وی با قطعه‌متن دریافتی و نام خانوادگی آن با نام خانوادگی فاعل برابر باشد، موجودیت به مجموعه‌ی پاسخ‌ها اضافه می‌شود.

۴- مجموعه‌ی داده

ارزیابی سیستم از طریق یک مجموعه‌ی داده‌ی تست انجام شد. از آن جایی که مجموعه‌ای داده‌ای که متناسب با موضوع ما باشد در دسترس نبود، مجموعه‌ای جدید از داده‌ها را ایجاد کردیم. برای اطمینان از اینکه یک مجموعه‌ی داده‌ی قابل اکتساب باشد، روشنی را که آقای West و همکاران [9] در ساخت مجموعه‌ی داده استفاده کردند به کار بردهیم. هر رکورد از داده‌ها یک دوتایی است که باید عنصر سوم آن به عنوان مفعول توسط سیستم مپیش‌بینی گردد. این دوتایی برای اینکه از فرضیات مستعلمه ما و مجموعه‌ی داده‌ی آقای West پیروی کنند باید چند ویژگی داشته باشند. عنصر دوم که معادل با رابطه می‌باشد در نهایت باید یکی از حالت‌های «همسر» یا «فرزنдан» داشته باشد و فاعل آن «اشخاصی» باشند که آقای West استفاده کرده است و یا حداقل اینکه «اشخاصی» باشند که به روشنی مشابه با روش آقای West و از منابع مشابه‌ای انتخاب شده باشند. آقای West و همکارانشان برای انتخاب فاعل‌ها ابتدا ۱۰۰ هزار شخصی را که بیشترین جستجو درباره‌شان در سطح وب صورت گرفته را به عنوان اشخاص پایه در نظر گرفتند. اما اینکه چه کسانی و با چه رتبه‌ای در این فهرست هستند را هم به صورت عمومی در اختیار نگذاشته‌اند. بنابراین اولین مرحله، یافتن ۱۰۰ هزار شخص است که از مهتم‌ترین افراد باشند. سیستمی که [13] طراحی کردند، جستجو در پایگاه‌دانش Freebase راحت و ساده می‌کند. علاوه‌بر این، آن‌ها به هر موجودیت در Freebase یک امتیاز اختصاص داده‌اند که شیوه‌ی امتیازدهی آن‌ها برای رتبه‌دهی به اشخاص استفاده شد و با کمک آن امتیازها ۱۰۰ هزار شخص مهمن و برجسته را یافته و برای ساخت مجموعه‌ی داده از آن‌ها استفاده کردیم. در ادامه‌ی ساخت مجموعه‌ی داده به روشن آقای West برمی‌گردیم. آن‌ها برای ساخت هریک از مجموعه‌های داده‌شان به ازای هر رابطه از نمونه‌گیری طبقه‌ای که در ادامه توضیح می‌دهیم، استفاده کردند: برای هر رابطه، از بین ۱۰۰ هزار نفر، تنها آن فاعل‌هایی را در نظر گرفتند که مقدار مفعول آن مشخص بود و مجھول نبود. سپس

شکل (۲) : عملکرد سیستم با توجه به معیار MRR



شکل (۴) : عملکرد سیستم با توجه به معیار precision



شکل (۵) : عملکرد سیستم با توجه به معیار recall



بررسی این معیار ارزیابی برای رابطه‌های «همسر» و «فرزندان» با استفاده از START و Wolfram|Alpha در شکل (۵) نشان داده شده است. همان طور که در نمودار مشخص است برای رابطه‌ی «فرزندان» در این زمینه موفقیت پیشتری کسب شده است. به طور کلی با درنظر گرفتن هر دو معیار precision و recall می‌توان چنین نتیجه گرفت که اگرچه برای رابطه‌ی «فرزندان» موجودیت‌های موردنظر این سیستم برای رابطه‌ی «همسر» نسبت به «فرزندان» هم حدس‌های پیشتری را پیش‌بینی می‌کند اما در این پیش‌بینی، به صورت نسبی اشتباه‌های پیشتری مرتكب شده است؛ هرچند این مقدار زیاد محسوس نیست. سیستم طراحی شده اگر مبتنی بر START اجرا شود نتیجه در قالب precision و recall نیز در مقایسه با Wolfram|Alpha ضعیفتر است. این تنظیم از سیستم برای رابطه‌ی «همسر» نسبت به رابطه‌ی «فرزندان» هم حدس‌های صحیح‌تری زده و هم موفق شده پیشتر از «فرزندان» نسبت به حالت موردنظر پیش‌بینی داشته باشد.

در کل با توجه به همه‌ی معیارهای ارزیابی، تنظیم Wolfram|Alpha به عنوان استخراج کننده‌ی متنی پاسخ‌ها می‌تواند نماینده‌ی موفقی از سیستم باشد زیرا در همه‌ی آن معیارها به نتایج قابل قبولی رسیده است.

۲- بحث و نتیجه گیری

در این پژوهش راهکاری برای تکمیل اطلاعات موجود در پایگاه‌های دانشنامه ارائه شد. این راهکار برای اشخاصی که اطلاعات همسر و فرزندان‌شان در Freebase موجود نیست پیشنهاد شده و آزمایش گردیده است. روش پیشنهادی از قابلیت دریافت پرسش‌های زبان طبیعی سیستم‌های پرسش-

West سیستم طراحی شده را از نظر این دو معیار ارزیابی، با سیستم آقای Wolfram|Alpha مقایسه کرده و مشاهده می‌شود زمانی که از سیستم پرسش و پاسخ برای مرحله‌ی استخراج پاسخ‌ها استفاده می‌شود نتیجه بهبود می‌یابد. برای رابطه‌ی «فرزندان»، این بهبود به شکل قابل توجهی محسوس می‌باشد. دلیل تفاوت در نتایج بین این دو رابطه می‌تواند به ماهیت رابطه و نوع نگاشت موجودیت‌ها بگذرد. اینکه معمولاً «فرزندان» بیشتر از «همسر» می‌توانند از روش سوم در نگاشت موجودیت پیروی کنند. اگر بخواهیم علت کمتر بودن مقادیر معیارهای ارزیابی را در حالت استخراج پاسخ بر اساس START بررسی کنیم، عامل آن می‌تواند ضعیفتر بودن سیستم پرسش و پاسخ START نسبت به سیستم زیرا START پاسخ‌ها را از کل وب باید جستجو کند در حالی که Wolfram|Alpha پایگاه‌دانش خود را که بسیار غنی است جستجو می‌کند. اگر بخواهیم روش Wolfram|Alpha را به عنوان نماینده‌ای موفق از سیستم طراحی شده با سیستم آقای West مقایسه کنیم و علت این تفاوت در نتایج را جستجو کنیم می‌توان به درنظر گرفتن همه‌ی قطعه‌های کوچک از پاسخ‌ها اشاره کرد. در سیستم جدید طراحی شده، اگر به عنوان مثال تنها نام کوچک یک شخص به عنوان پاسخ در دسترس باشد و استخراج شده باشد، همین اطلاعات کم توسط سیستم مورد استفاده قرار می‌گیرد و سعی می‌شود با استفاده از آن موجودیت کاندید حدس زده شود. این در حالی است که روش-های مشابه ممکن است قطعه متن‌هایی که خود به تنهایی اطلاعات تعیین-کننده‌ای ندارند را نادیده بگیرند. همین مسئله باعث می‌شود امکان پیش‌بینی‌های بیشتر برای سیستم ما فراهم شود. این امکان در صورتی می‌تواند به جواب‌های صحیح بیشتر منجر شود که مرحله‌ی استخراج متنی پاسخ‌ها از طریق منابع غنی افقی بیفتند.

دلیل دیگری که در درنتیجه می‌تواند موثر باشد تفاوت عملکرد سیستم برای استخراج اطلاعات می‌باشد. آن سیستم کل وب را برای یافتن پاسخ با استفاده از یک سیستم پرسش و پاسخ خودساخته چستجو می‌کند و این چستجو از طریق چندین پرسش و جوهر صورت می‌گیرد. همین مسئله می‌تواند در عین حال که پاسخ‌های صحیح بیشتری را منجر شود، پاسخ‌های اشتباه دیگری را هم در صورت برخورد نادقيق با جواب‌های استخراجی و به دلیل وسعت اطلاعات ایجاد کند. بنابراین پاید مکانیزم دقیقی برای استخراج نهایی پاسخ از بین آن‌ها داشته باشد تا از اشتباه‌ها جلوگیری شود و در رتبه‌بندی نهایی بیشتر شاهد پاسخ‌های صحیح باشیم.

به عنوان معیار ارزیابی دیگر برای مقایسه عملکرد سیستم در دو رابطه‌ی «همسر» و «فرزندان» می‌توان از precision و recall کمک گرفت. معیار precision نشان می‌دهد از بین همه‌ی موجودیت‌هایی که توسط سیستم پیش‌بینی شده، چند مورد از آن‌ها صحیح پیش‌بینی شده‌اند. تفاوت عملکرد این معیار برای هردو روش استخراج متنی پاسخ‌ها و برای هر دو رابطه‌ی «همسر» و «فرزندان» در شکل (۴) قابل مشاهده می‌باشد. همان‌طور که این نمودار نشان می‌دهد در حالت Wolfram|Alpha سیستم برای رابطه‌ی «همسر» موفق شده است از بین کل موجودیت‌هایی که برای آن رابطه پیش‌بینی کرده است، پیش‌بینی‌های صحیح‌تری داشته باشد. از زوایدی دیگر، اگر از کل موجودیت‌هایی که باید سیستم پیش‌بینی می‌کرد، تعداد آن‌هایی که توانسته پیش‌بینی کند را بدست آوریم؛ درواقع recall آن را یافته‌ایم. نتیجه‌ی

- [9] West, Robert, Evgeniy Gabrilovich, Kevin Murphy, Shaohua Sun, Rahul Gupta, and Dekang Lin. "Knowledge base completion via search-based question answering." In Proceedings of the 23rd international conference on World Wide Web, pp. 515-526. ACM, 2014.
- [10] Katz, Boris. "Annotating the World Wide Web using natural language." In Computer-Assisted Information Searching on Internet, pp. 136-155. LE CENTRE DE HAUTES ETUDES INTERNATIONALES D'INFORMATIQUE DOCUMENTAIRE, 1997.
- [11] MIT InfoLab. START. <http://start.csail.mit.edu/index.php>.
- [12] Wolfram Alpha LLC. Wolfram|Alpha. <http://www.wolframalpha.com>.
- [13] Bast, Hannah, Florian Bäurle, Björn Buchhold, and Elmar Haußmann. "Easy access to the freebase dataset." In Proceedings of the 23rd International Conference on World Wide Web, pp. 95-98. ACM, 2014.
- [14] Fellbaum, Christiane. WordNet. Blackwell Publishing Ltd, 1998.

وپاsx استفاده کرده و سعی می کند از این طریق، بخش های مجهول از پایگاه داده را به صورت متنی بیابد. از آنجایی که در سیستم طراحی شده فرض شده که هیچ اطلاعات جانبی دیگری در دسترس نیست که با تکنیک های متن کاوی و شباهت یابی پاسخ های متنی را به موجودیت های صحیح نگاشت دهد، سعی می کند با استفاده از رابطه های مبتنی بر پایگاه داده، روابط خانوادگی، ماهیت رابطه و موجودیت موردن جستجو نگاشت موجودیت را با حداقل اطلاعات در دسترس انجام دهد. آن راه حل پیشنهادی که مبتنی بر سیستم پرسش و پاسخ Wolfram|Alpha است، در مقایسه با کار مشابه در گذشته موفق شده از نظر معیارهای MRR و MAP بظهور یابد.

به عنوان کارهایی که در آینده می توان برای سیستم انجام داد، ببینید آن در رابطه های مهم دیگری است. در صورتی که ماهیت موجودیت های موردن جستجو امکان ارتباط با منابع معنایی مانند WordNet [14] را فراهم کند، از این امکان استفاده شود تا قوانین بیشتری استخراج شود. همچنین می توان مرحله استخراج اطلاعات متنی را با استفاده از منابع متنی یا ساختار یافته هی قابل اتکا مانند صفحات بیوگرافی افراد ببینید.

زیرنویس ها

-
- ¹ Databases
 - ² Entity
 - ³ Lexical Analysis
 - ⁴ Resource Description Framework
 - ⁵ Query
 - ⁶ Search Engines
 - ⁷ Knowledge-Sharing Communities
 - ⁸ Facts
 - ⁹ Question Answering (QA)
 - ¹⁰ <http://www.imdb.com/>

مراجع

- [1] Bollacker, Kurt, Colin Evans, Praveen Paritosh, Tim Sturge, and Jamie Taylor. "Freebase: a collaboratively created graph database for structuring human knowledge." In Proceedings of the 2008 ACM SIGMOD international conference on Management of data, pp. 1247-1250. ACM, 2008.
- [2] Vrandečić, Denny. "Wikidata: A new platform for collaborative data collection." In Proceedings of the 21st International Conference on World Wide Web, pp. 1063-1064. ACM, 2012.
- [3] Suchanek, Fabian M., Gjergji Kasneci, and Gerhard Weikum. "Yago: a core of semantic knowledge." In Proceedings of the 16th international conference on World Wide Web, pp. 697-706. ACM, 2007.
- [4] Wu, Wentao, Hongsong Li, Haixun Wang, and Kenny Q. Zhu. "Probase: A probabilistic taxonomy for text understanding." In Proceedings of the 2012 ACM SIGMOD International Conference on Management of Data, pp. 481-492. ACM, 2012.
- [5] Rodriguez, Miguel, Sean Goldberg, and Daisy Zhe Wang. "SigmaKB: multiple probabilistic knowledge base fusion." Proceedings of the VLDB Endowment 9, no. 13 (2016): 1577-1580.
- [6] Auer, Sören, Christian Bizer, Georgi Kobilarov, Jens Lehmann, Richard Cyganiak, and Zachary Ives. "Dbpedia: A nucleus for a web of open data." In The semantic web, pp. 722-735. Springer Berlin Heidelberg, 2007.
- [7] Zhu, Jun, Zaiqing Nie, Xiaojiang Liu, Bo Zhang, and Ji-Rong Wen. "StatSnowball: a statistical approach to extracting entity relationships." In Proceedings of the 18th international conference on World Wide Web, pp. 101-110. ACM, 2009.
- [8] Etzioni, Oren, Michael Cafarella, Doug Downey, Stanley Kok, Ana-Maria Popescu, Tal Shaked, Stephen Soderland, Daniel S. Weld, and Alexander Yates. "Web-scale information extraction in knowitall:(preliminary results)." In Proceedings of the 13th international conference on World Wide Web, pp. 100-110. ACM, 2004.