

ساخت هستان‌شناسی دانش عرفی زبان

فارسی با رویکردی تلفیقی

مهدی مرادی

کارشناسی ارشد زبان‌شناسی رایانشی؛
دانشگاه صنعتی شریف
mehdi.moradi.cl@gmail.com

بهرام وزیرنژاد

دکتری مهندسی پزشکی؛
استادیار؛ دانشگاه صنعتی شریف
bahram@sharif.edu
پدیدآور رابط

محمد بحرانی

دکتری هوش مصنوعی؛
استادیار؛ دانشگاه صنعتی شریف
bahrani@sharif.edu

دریافت: ۱۳۹۷/۰۳/۲۷

پذیرش: ۱۳۹۶/۰۱/۲۳

مقاله برای اصلاح به مدت ۳۹ روز نزد پدیدآوران بوده است.

بجهی اطلاعات

پژوهشنامه پژوهش و مدیریت اطلاعات
فصلنامه | علمی پژوهشی
پژوهشگاه علوم و فناوری اطلاعات ایران
شما (چاپی) ۲۲۵۱-۸۲۲۲
شما (الکترونیکی) ۲۲۵۱-۸۲۳۱
نمایه در SCOPUS، ISC، LISTA و
دوره ۳۱ | شماره ۱ | ص ص ۱۰۹-۱۲۴
پاییز ۱۳۹۴

مقاله پژوهشی

چکیده: تجهیز رایانه‌ها به دانش عرفی پسر همواره یکی از جاه طلبانه ترین اهداف علم هوش مصنوعی بوده است. میلیون‌ها دلار هزینه و هزاران ساعت زمان صرف شده تا رایانه‌ها بفهمند که «اشیاء بالا نمی‌روند، بلکه می‌افتد» و «دویدن از راه رفتن سریع‌تر است». پایگاه‌های دانش عظیمی ساخته شده، روش‌های خودکار و نیمه خودکار متن کاوی پیشنهاد شده و از انگیزه همکاری کاربران عادی اینترنت به نفع اکتساب این دانش بهره‌های بزرده شده است، ولی رسیدن به روشی خودکار، مؤثر و کم خطای همچنان به صورت چالشی بزرگ پیش روی جامعه هوش مصنوعی باقی مانده است. هدف این تحقیق ساخت هستان‌شناسی دانش عرفی فارسی به کمک سه روش مبتنی بر الگو، ترجمه ماشینی و استفاده از منابع ساخت یافته است. با کمک سه پیکرۀ مختلف فارسی هفت نوع روابطه و در مجموع هفتاد هزار اظهار (رابطه) استخراج شده و در قالب یک هستان‌شناسی ارائه شد. نتایج بررسی گویشوران فارسی نشان داد که میانگین دقت روابط استخراج شده این هستان‌شناسی برابر با ۷۵ درصد برای اطلاعات استخراج شده از جمعیۀ اطلاعات بود.

کلیدواژه‌ها: دانش عرفی؛ هستان‌شناسی؛ استخراج رابطه

۱. مقدمه

با وجود پیشرفت‌های خیره‌کننده عصر تکنولوژی، هنوز رایانه‌ها به آن درجه از درک و شعور نرسیده‌اند که هفت ژوئن هر سال به احترام پدرشان «آلن تورینیگ»^۱ لحظه‌ای سکوت کنند و به سوگ بنشینند. رایانه‌های امروزی قادرند ماهرترین شطرنج‌بازان را شکست دهنند، قضایای مهم ریاضی را کشف و اثبات کنند، علائم و مراحل پیشرفت بیماری را تشخیص دهنند، ولی هنوز نمی‌دانند که اشیاء بالا نمی‌روند، بلکه می‌افتد، پدران از فرزندانشان بزرگ‌ترند و دادزدن نشان از عصبانیت فرد دارد. عمدۀ ترین دلیل برای ناتوان جلوه کردن رایانه‌ها، عدم دسترسی به همین حقایق پیش‌پالفناه و ساده است. همین حقایق ساده وجه تمایز میان انسان و سیستم‌های هوشمند نسل جدید است (Lieberman 2008). هر چند استفاده از روش‌های مبتنی بر کلمات کلیدی و روش‌های آماری در سیستم‌های هوشمند، بازیابی اطلاعات، داده‌کاوی و پردازش زبان طبیعی به موقعيت‌هایی دست یافته است، ولی متخصصان این حوزه معتقدند که این روش‌ها تنها در کی سطحی از متون ارائه می‌دهند و برای پیشرفت در مدیریت اطلاعات و دستیابی به درکی عمیق‌تر از متون، برنامه‌های مان نیازمند دسترسی به حجم گسترده‌ای از دانش معنایی دنیای پیرامون خود هستند؛ دانشی که دربر گیرنده طیف وسیعی از تجربه و توانایی بشری است، حقایقی در مورد دانش و چگونگی اکتساب آن، حقایقی در مورد رخدادها و پیامدهایشان، اشیاء و ویژگی‌های آنها و نیز عقاید و علایق (McCarthy 1990). میلیون‌ها حقیقت کوچک روزمره و توانایی استفاده از این حقایق در موقع نیاز، گنجینه دانش عرفی^۲ (فهم عمومی، فهم عرفی، یا فهم متعارف) بشر را تشکیل می‌دهد. دانش عرفی به مجموعه حقایقی گفته می‌شود که انتظار دانستن از هر فرد عادی می‌رود. «سوzen تیز است»، «برای باز کردن در، ابتدا باید دستگیره را چرخاند» و «مردم معمولاً شب‌ها می‌خوابند». محققان هوش مصنوعی از دیرباز به اهمیت بازنمایی محاسباتی این دانش در سیستم‌های هوشمند واقف بوده‌اند (McCarthy 1959) و تلاش‌های گسترده‌ای نیز برای بازنمایی این دانش انجام شده است. مراکز علمی – پژوهشی جهان سرمایه‌مالی – انسانی هنگفتی صرف تجهیز رایانه‌ها به دانش عرفی کرده‌اند (Lenat 1995؛ Lenat et al. 2002؛ Sing and et al. 2002) و دهه اخیر نیز شاهد گام‌هایی بلند در زمینه استخراج، بازنمایی و استفاده از این دانش بوده است. پایگاه‌های دانش نسبتاً بزرگی ساخته شده و کاربردهای مختلفی برای آنها پیشنهاد شده است. سیستم‌های پرسش و پاسخ (Q/A)^۳، سیستم‌های استنتاج‌گر (RTE)^۴، موتورهای جستجو، سامانه‌های چند‌عامله^۵، خلاصه‌سازی متن، و تشخیص احساس^۶ نمونه‌هایی از کاربردهای این دانش است. با این وجود، تلاش‌های

1. Alan Turing

2. commonsense knowledge

3. question answering

4. recognizing textual entailment

5. multi-agent system

6. emotion detection (sentiment analysis)

صورت گرفته برای استخراج این دانش برای زبان فارسی و نیز تنوع روش‌های مورد استفاده برای این زبان، محدود و انگشت‌شمار بوده است (شمس‌فرد، و عبدالهزاده بارفروش ۱۳۸۱).

۲. مروجی بر منابع

۱-۱. دانش عرفی

فیلسوفان، اولین کسانی بودند که دانش عرفی، ذهن پرسشگرshan را به اندیشه واداشت. از نظر اسطو دانش عرفی^۱ از قوای باطنی است که صور حاصل از حواس ظاهری در آن جمع و بهوسیله آن ادراک می‌شوند (Lories 1991). رواقیون این دانش را «درک عمومی»^۲ می‌نامیدند، یعنی عقایدی که همگان بدون نیاز به اثبات واستدلال بدان اعتقاد دارند (Lories 1998). بنا به عقیده دکارت دانش عرفی جزو محدود چیزهایی است که عادلانه بین همگان توزیع شده و حریص‌ترین افراد نیز نیازی به اکتساب بیشتر آن نمی‌بینند (Descartes 2008). «جان‌مک‌کارتی» اولین کسی بود که به ضرورت این دانش در سیستم‌های هوشمند پی‌برد. به نظر وی «برنامه‌ای دارای دانش عرفی است» که بتواند به صورت خودکار، برای خود در مورد طیف گسترده‌ای از پیامدهای بی‌درنگ هر چیزی که به آن ارائه می‌شود و نیز هر آنچه از قبل می‌داند، استنتاج کند (McCarthy 1959).

۲-۱. استخراج و بازنمایی دانش عرفی

۲-۱-۱. سایک

«سایک»^۳ جزو اولین پژوهه‌ها در زمینه بازنمایی دانش عرفی بود. مهندسان دانش استخدام شده، به صورت دستی حقایق اولیه مرتبط با فهم عمومی را در قالب زبان «سایک ال» وارد این آنتولوژی می‌کردند. «سایک ال» زبان اختصاصی «سایک» بود که علاوه بر دقت، قادر ابهامات زبان طبیعی نیز بود. با کمک این حقایق اولیه، حقایق بیشتری (برای مثال، از طریق استنتاج) نیز به پایگاه دانش این پژوهه افزوده گشت (Lenat 1995). با این وجود، وارد کردن میلیون‌ها حقیقت عرفی، خارج از توان چند ده مهندس دانش بود و این امر پیشرفت پژوهه را کند و پرهزینه می‌کرد.

۲-۱-۲. پژوهه اوپن مایند کامن سنس

پژوهه اوپن مایند کامن سنس^۴ خلاقانه‌ترین روش برای جمع‌آوری این دانش را به کار گرفت. این پژوهه که در مدیا لب^۵ دانشگاه ام‌آی‌تی کلید خورد، برخلاف پژوهه «سایک»، متکی بر

1. Sensus communis
4. Open mind commonsense project

2. Ennoai koinai
5. Media lab

3. Cyc

کاربران عادی اینترنت بود. پانزده هزار داوطلب در مدت زمانی کم و بدون هیچ چشم‌داشتی بیش از یک میلیون حقیقت عرفی را به پایگاه این آنلولوژی افروزند (Push Singh et al. 2002).

۲-۳. بازی‌های هدف‌دار^۱

در پژوهه «اوپن مایند کامن‌سنس»، مستقیماً از کاربران خواسته می‌شد که دانش عرفی را وارد پایگاه دانش کنند. ولی، اخیراً رویکرد دیگری توجه پژوهشگران را به خود جلب کرده است: استفاده از بازی‌های هدف‌دار که در آن امتیاز هر بازیکن به کمک دانشی که ارائه می‌کند، سنجیده می‌شود. پیشگامان این ایده خلاقانه (رایانش انسان محور) Luis von Ahn et al. (2006) بودند که بازی ورباستی^۲ را برای جمع‌آوری دانش عرفی از کاربران طراحی کردند. «کامن کانسنسوس»^۳ نام بازی دیگری بود که هدف اصلی طراحانش جمع‌آوری اهداف انسان به عنوان بخشی از دانش عرفی بود (Lieberman et al. 2007).

۲-۴. روش مبتنی بر الگو^۴

در این روش، که برای اولین بار توسط «هرست» معرفی شد، به استفاده از کلمات خاص و نیز به کمک مقوله نحوی کلمات، دانش مفهومی از متن غیرساخت‌یافته استخراج می‌شود (Hearst 1992). برای افزایش دقت در این متد، از دو روش بهره می‌برند. روش اول، استفاده از چندین الگوی مختلف برای هر رابطه (جهت پوشش حداکثری جملات هدف)، و روش دوم، انجام پس‌پردازش بر روی جملات استخراج شده است. «شمس‌فرد و عبداله‌زاده بارفروش» با معرفی الگوهای زبانی و معنایی که مستقل از دامنه و کاربرد هستند، توانستند روابط طبقه‌ای و غیرطبقه‌ای و اصول بدیهی را از جملات فارسی استخراج کنند (شمس‌فرد و بارفروش ۱۳۸۱). «مرادی» و همکاران توانستند با استفاده از روش مبتنی بر الگو از ۱۵۰ هزار مقاله فارسی و یکی‌پدیا ۳۸۹۲ جمله عمومی استخراج کنند (۱۳۹۱).

۳. مواد و روش‌ها

۱-۱. پیکره‌ها

۱-۱-۱. پیکره همشهری

این پیکره یکی از معتبرترین پیکره‌ها در زبان فارسی بوده و اساسش متون خبری روزنامه همشهری است. این پیکره در فرمت xml است (آل احمد و دیگران ۲۰۰۹).

1. game with a purpose (GWAP)
2. human computation
3. Verbosity
4. common consensus

جدول ۱. پیکره همشهري

| پیکره همشهري | |
|--------------|-----------------------------|
| نحوه | معيار |
| ۷۰۰ مگابايت | حجم (يوني كد ^۱) |
| ۱۶۰۰۰ | تعداد استناد |
| ۶۳۵۱۳۸۲۷ | تعداد كلمه |

۱-۳-۲. پیکره بی جن خان^۲

حجم داده‌های این پیکره یک‌صد میلیون کلمه و دارای داده‌های نوشتاری (حدود ۴۱۷ مگابايت و شامل نود میلیون کلمه) و داده‌های گفتاری (در حدود ده میلیون کلمه) است. مجموعه نود میلیون کلمه‌ای از پیکره یاد شده در این تحقیق مورد استفاده قرار گرفت. با توجه به حجم این پیکره از متون نگارشی فارسی و نیز معیاربودن آن از نظر تنوع متنی، این پیکره یکی از جامع‌ترین پیکره‌های فارسی است (امیری و دیگران ۱۳۸۵).

جدول ۲. پیکره بی جن خان

| پیکره بی جن خان | |
|-----------------|--------------|
| نحوه | معيار |
| ۴۷۶ | حجم |
| ۳۵۰۵۹ | تعداد استناد |
| متن ساده | نوع سند |
| ۹۹۷۶۱۱۱۴ | تعداد كلمه |

۱-۳-۳. ويکي پديا

ويکي پديا دانشنامه‌ای اينترنتي، چندزبانه و با محتويات آزاد است که با همکاري افراد داوطلب نوشته می‌شود و مقالات آن می‌تواند توسط هر کسی که به اينترنت دسترسی دارد، ويرايش گردد. ويکي پدياي فارسی با داشتن حدود ۲۳۰ هزار مقاله در حوزه‌های مختلف پیکره متنی مناسبی جهت مطالعات زبانی می‌باشد. ويکي پديا به کاربران اين امكان را می‌دهد که نسخه كاملی از تمامی مقالات را در قالب يك فايل با فرمت XML دانلود کنند. برای انجام اين تحقیق نسخه 03/06/2012 اين دانشنامه بارگذاري شده و مورد استفاده قرار گرفت.

1. unicode

2. Bijakhan

جدول ۳. پیکره متنی ویکی‌پدیا

| پیکره ویکی‌پدیا | |
|-----------------|--------------|
| نسخه ۱ | معیار |
| ۲۷/۱ گیگا | حجم |
| ۱۷۸۰۰۰ | تعداد استناد |
| XML | نوع سند |
| ۲۹۷۳۴۹۲۳ | تعداد کلمه |

۲-۳. روش استخراج

در این تحقیق سعی شده است که الگوهای مورد جستجو با توجه به روابط تعریف شده در «کانسپتنت»^۱ انگلیسی استخراج شود (ضمایم جدول ۲). روش استخراج دانش عرفی در این پژوهه یک روش ترکیبی مشتمل بر رویکردهای مختلف نظیر استخراج جملات دارای الگوهای خاص از پیکره‌های زبانی، ترجمه دانش عرفی موجود در «کانسپتنت» و نیز استفاده از اطلاعات ساخت‌یافته «ویکی‌پدیا» بوده است. هر یک در ادامه توضیح داده شده است.

۲-۳-۱. استخراج به روش مبتنی بر الگو

در روش‌های مبتنی بر الگو، با کمک الگوها و کلیدواژه‌های خاص روابط مورد نظر استخراج می‌شود رابطه "Is A" ، "Used For" و "Made Of" و روابط تضاد و هم معنایی از این طریق استخراج شد. از تکنیک «بوت استرینگ»^۲ برای استخراج الگوها استفاده شد.

◇ تکنیک «بوت استرینگ» برای استخراج الگوها:

(۱) استخراج الگو:

۱. انتخاب چند نمونه که به خوبی رابطه مورد نظر را نشان دهد
 ۲. جستجوی عبارات فوق در موتور جستجوی گوگل
 ۳. ذخیره ۱۰۰ صفحه اول حاوی این جستجوها
 ۴. تقطیع هر سند به جملات سازنده آن
 ۵. ذخیره جملاتی که حاوی کلمات جستجو بودند و نیز نرمال‌سازی نویسه‌ها و فاصله‌ها و نیز حذف برچسب‌های .html
- (۲) بازنویسی الگوهای استخراج شده در قالب عبارات منظم

1. ConceptNet

2. Bootstrapping

(۳) استخراج جملات دارای الگوی مورد نظر

(۴) انجام پس پردازش به منظور حذف عبارات نامرتب

برای مثال: برای رابطه "Is A" پرس و جوهای ارسالی به گوگل عبارات زیر بودند:

الف- «شیر، ماست، پنیر، خامه، کره، بستنی، شیر خشک»

ب- «دیابت، قلب، کلیه، کیسه صفراء»

ج- «عدس، لوبیا، نخود»

د- «مس، نقره، پلاتین»

پس از بررسی جملات استخراج شده از نتایج گوگل، الگوهای زیر برای استخراج رابطه "Is A" بازنویسی شد.

جدول ۴. الگوهای رابطه "Is A"

| شماره | الگوی مورد استفاده | مثال |
|-------|--|---|
| ۱ | Xهایی (نظیر مانند همانند | گازهایی مانند دی اکسید کربن، سولفید، هیدروژن، آمونیاک، مونوکسید |
| ۲ | همچون چون از قبیل مثل از جمله از قبیل) | y1, y2, y3 (از جمله)، Xهای |
| ۳ | Xها عبارت اند از y3 y1, y2, y3 | غذاهای دیرهضم عبارت اند از: جبویات و غلات مثل فیلمهای شاخص |
| ۴ | Xها اعم از y3 y1, y2, y3 | دانه‌ها اعم از گندم، جو یا عدس |
| ۵ | (y1, y2, y3) Xها انواع | برنز، برنج |
| ۶ | Xها (به خصوص، به ویژه، آلمان ...) مخصوصاً y1, y2, y3 | همه کشورهای اروپایی، به خصوص انگلستان، فرانسه و |

پس از استخراج جملات پس پردازش‌هایی بر روی آنها انجام گرفت تا بخش‌های زائد جملات حذف گردد.

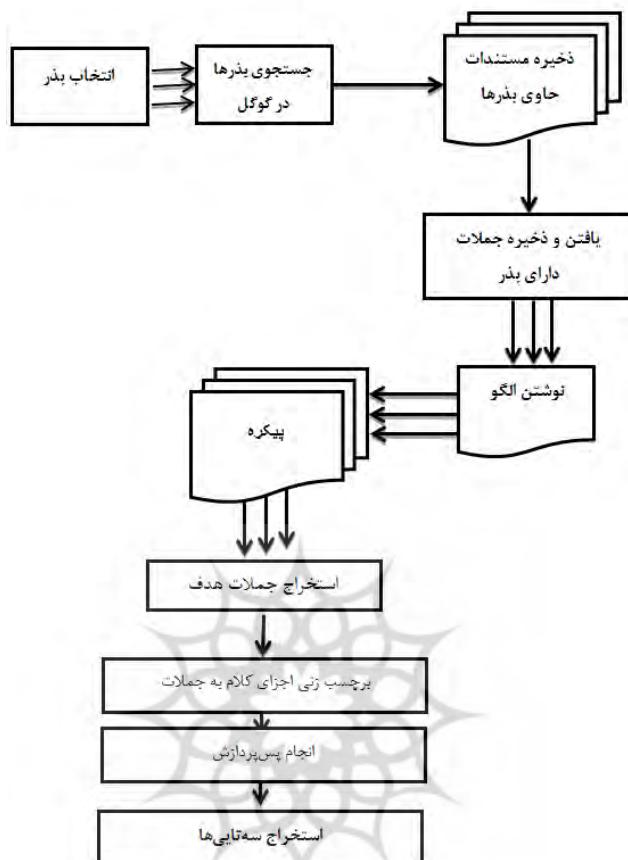
الگوهای زیر برای استخراج رابطه "Used For" بازنویسی شدند:

جدول ۵. الگوهای مورد استفاده برای استخراج رابطه "Used For"

| شماره | الگوی مورد استفاده | مثال |
|-------|-----------------------------|--|
| 1 | X (برای به منظور جهت) | ناقوس‌ها برای فراغوان دفاع شهری و اعلام خطر آتش‌سوزی نیز به کار برده می‌شود. |
| 2 | X برای ۷ ضروری | اتصال کلسیم به میوزین برای انقباض عضلات صاف جدار عروق ضروری است. (است می‌باشد). |
| 3 | برای X از ۷ (کمک استفاده) | برای بردین ورق‌ها از انواع قیچی‌های دستی و یا ماشینی کمک می‌گیرند. |
| 4 | از X برای ۷ (استفاده) | از http برای دسترسی به برگه‌های وب نرم‌افزار استفاده می‌شود. |
| 5 | هدف از X، ۷ است | هدف از عکاسی اچ‌دی‌آر، افزایش محدوده دینامیکی است. |
| 6 | X برای (درمان) ۷ تجویز | هالوپریدول برای درمان روان‌پریشی تجویز می‌شود. |
| 7 | X وسیله است برای ۷ | پرگار وسیله‌ای برای کشیدن دایره است. |



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی



شکل ۱. روند کلی استخراج چندتایی‌ها با روش مبتنی بر الگو

۲-۲-۳. ترجمه ماشینی

بخش بزرگی از دانش عرفی در قالب جملات عمومی^۱ بیان می‌گردد؛ جملاتی مانند: الف) فلزات جامدند، ب) پستانداران بچه‌زا هستند. به چنین جملاتی که قاعده‌ای عمومی، برای مثال، راجح به فلزات یا پستانداران بیان می‌کنند و معمولاً ساختار زبانی ساده‌ای دارند، جملات عمومی گفته می‌شود (Carlson et al. 1995). لذا، استفاده از مترجم‌های ماشینی در این مورد، علیرغم ضعف آنها در ترجمه عبارات پیچیده، گزینه مناسبی خواهد بود. از این‌رو، با توجه به (۱) ساختار ساده جملات عمومی (۲) هزینه و زمان مورد نیاز برای ساخت یک آنتولوژی نو برای زبان فارسی (۳) دقت پایین روش مبتنی بر الگو در استخراج بعضی از روابط (مانند رابطه توالی

1. Generic sentence

رخدادها، محرك‌ها و على‌ها (جدول ۴) و ۴) غنای مفاهیم و روابط موجود در «کانسپتنت» انگلیسی، تصمیم گرفته شد که اظهارات این آنتولوژی به زبان فارسی ترجمه شود. از بین مترجم‌های ماشینی موجود در بازار، ۵ مترجم گوگل، بایلون، مترجم پینگ (مایکروسافت)، مترجم پدیده از زبان فارسی پشتیبانی می‌کنند. پس از انتخاب ۲۰ اظهار تصادفی از هر رابطه موجود در «کانسپتنت»، از ۱۰ مترجم خواسته شد که نتایج ترجمه‌این اظهارات توسط مترجم‌های ماشینی را رتبه‌بندی کنند (۰ برای ترجمه نامفهوم، ۱ برای ترجمه‌ای که مفهوم آن را باید حدس زد، ۲ ترجمه قابل قبول، ۳ ترجمه خوب). نتایج رتبه‌بندی نشان از کیفیت بهتر مترجم گوگل داشت (ضمایم نمودار ۱). از این‌رو، در این پژوهه از این ترجمه کننده برای ترجمه اظهارات «کانسپتنت» استفاده شد.

پیش‌پردازش «کانسپتنت» و پس‌پردازش اظهارات ترجمه شده
بعد از انجام پیش‌پردازش‌های لازم، اظهارات با مترجم گوگل ترجمه شدند. از بین روابط ترجمه شده توسط گوگل، فقط روابط Property Of، Made Of، Part Of، Location OF، بهترین کیفیت بالای ترجمه (شکل ۳ به ترتیب شامل ۱۶۰۰۰، ۱۳۰۰۰، ۱۵۰۰، ۹۱۰۰ اظهار بودند، به دلیل کیفیت بالای ترجمه (شکل ۳ ضمایم) برای قرارگرفتن در آنتولوژی فارسی انتخاب شد. جدول شماره ۱، بخش ضمایم، نمونه‌ای از ترجمه اظهاری از هر رابطه توسط گوگل را نشان می‌دهد.

۳-۲-۳. استفاده از جعبه اطلاعات ویکی‌پدیا

بعضی مقالات ویکی‌پدیا یک یا چند جعبه اطلاعات در خود دارند (شکل ۴). جعبه اطلاعات به الگوهایی گفته می‌شود که معمولاً در بالای مقاله قرار می‌گیرند و اطلاعاتی کلی در مورد موضوع مقاله ارائه می‌دهند. هر سطر از جعبه اطلاعات یک ویژگی و یک مقدار دارد. برای مثال، جدول مربوط به «غلامحسین ابراهیمی دینانی» فیلسوف، دارای ویژگی زادگاه با مقدار اصفهان، ایران، دین با مقدار مسلمان دارد. بعد از استخراج تمامی این جعبه‌ها، ۲۸۰۰ رابطه "Is A" با بازخوانی ۱۰۰ درصد از این جعبه‌ها استخراج شد.



شکل ۲. نمونه‌ای از یک جعبه اطلاعات ویکی‌پدیا

۴. بحث و نتیجه‌گیری

به‌زعم نویسنده‌گان، علیرغم کارهای صورت گرفته برای استخراج بعضی از روابط مفهومی (مانند رابطه A) از متن فارسی، تاکنون تحقیق جامعی که هدف اصلی اش را استخراج دانش عرفی قرار داده باشد، انجام نشده است. نتایج بدست آمده در این تحقیق نشان می‌دهد که استفاده از روش ترکیبی (روش‌های متن کاوی، ترجمه ماشینی و استفاده از جعبه اطلاعات و یکی‌پدیدای) به منظور استخراج دانش عرفی، علیرغم کاستی‌های موجود در حوزه زبان‌شناسی فارسی و نبود ابزارهای مورد نیاز حوزه زبان‌شناسی رایانشی فارسی می‌تواند نویدبخش حوزه‌ای پویا در استخراج و بازنمایی دانش عرفی باشد. ما در این تحقیق توانستیم از سه پیکره مختلف فارسی، هفت نوع رابطه استخراج کرده و الگوهایی برای استخراج روابط مربوط به دانش عرفی فارسی معرفی کنیم که در دیگر حوزه‌های مرتبط با بازیابی اطلاعات و اکتساب دانش مفهومی نیز کاربرد داشته باشد. در مقایسه با کارهای صورت گرفته بر روی زبان فارسی (Shamsfard et al. 2010) مزیت این تحقیق تازگی موضوع، استفاده از چند روش مختلف استخراج و نیز تعداد پیکره‌های مورد استفاده

بوده است. علاوه بر این، در این تحقیق تعداد رابطه‌های استخراج شده نسبت به تحقیقات پیشین به مراتب بیشتر بوده است. در مقایسه با کارهای صورت گرفته بر روی زبان انگلیسی دقت استخراج‌ها کمتر بوده است که دلیل این امر هم نبود پیکره‌های استاندارد فارسی و عدم توسعه ابزارهای اولیه و استاندارد پردازش متن فارسی است (Herdagdelen 2010; Sangun et al. 2007).

برای ارزیابی میزان دقت استخراج این نوع روابط، از دو گویشور زبان فارسی خواسته شد که نسبت به دانش عرفی بودن یا نبودن ۱۰۰ جمله از هر رابطه که به صورت تصادفی انتخاب شده بودند، قضاوت کنند (جدول ۷). نتایج بدست آمده نشان می‌دهد که در گروه روابط استخراج شده به روش مبتنی بر الگو هر دو رابطه دقت خوبی داشته‌اند و در این گروه دقت رابطه Used For نسبت به رابطه A Is A (رابطه A استخراج شده از جعبه اطلاعات و یکی‌پدیدا دقت ۱۰۰ درصد داشت) بیشتر است، هر چند جملات این گروه نسبت به رابطه قبلی نیاز به پس‌پردازش‌های بیشتری دارند. در گروه روابط ترجمه شده از «کانسپت‌نت» بیشترین دقت‌ها به ترتیب مربوط به Property Of، Location Of، Part Of و Made Of بود.

به عنوان پیشنهاد برای تحقیقات آینده و به منظور استخراج روابط بیشتر و نیز افزایش میزان دقت می‌توان از دیگر تکنیک‌های پردازش زبان طبیعی مانند برچسب‌زن گروه، برچسب‌زن معنایی، پیکره‌های مناسب‌تر و بزرگ‌تر، الگوهای غنی‌تر و بیشتر استفاده کرد. علاوه بر این، استفاده از روش‌های خلاقانه مانند رایانش انسان محور نیز می‌تواند به عنوان روشی مناسب جهت جمع‌آوری دانش عرفی فارسی مورد استفاده قرار گیرد. راه‌اندازی بخش فارسی پروژه «اوین مایند کامن سنس» نیز می‌تواند کمک شایانی به گسترش دانش عرفی محاسباتی فارسی بکند.

جدول ۶. دقت و تعداد هر کدام از روابط

| ردیف | نام رابطه | تعداد | حجم روابط استخراج شده |
|------|-------------|-------|-----------------------|
| ۱ | ترادف | ۷۵ | ۱۵۴۰ درصد |
| ۲ | Is A | ۷۵ | ۹۲۵۵ مبتنی بر الگو |
| ۳ | Used For | ۹۰ | ۱۲۴۴ جعبه اطلاعات |
| ۴ | Part Of | ۷۱ | ۶۴۰۰ درصد |
| ۵ | Made Of | ۶۸ | ۱۲۹۳۴ درصد |
| ۶ | Location Of | ۶۳ | ۱۵۱۹ درصد |
| ۷ | Property Of | ۷۷ | ۲۸۸۰۵ درصد |
| | | ۹۱۳۵ | |

۵. ضمایم

جدول ۱. نمونه‌ای از ترجمه‌های گوگل برای هر رابطه

| ش | ترجمه گوگل | متن اصلی | نوع رابطه |
|----|---|--|-----------------------------|
| ۱ | «فنلاند» و «اتحادیه اروپا» | “Finland” “European union” | Part Of |
| ۲ | «تلفن» «دستگاه الکتریکی» | “phone” “electrical device” | Is A |
| ۳ | «آجر و سنگ» | “House” “brick and stone” | Made Of |
| ۴ | «مسجد» «مسلمان» | “mosque” “muslim” | Property Of |
| ۵ | «عقاب» و «نماد ایالات متحده آمریکا» | “Eagle” “emblem of usa” | Defined As |
| ۶ | «کنسرت راک» و «جذب جمعیت» | “rock concert” “attract crowd” | Capable Of |
| ۷ | «فرد خانواده خوراک» و «فرد طبخ مواد غذایی» | “feed person 's family” “cook person 's food” | Subevent Of |
| ۸ | «شستن خاک از بین فرد پا» و «فرد» کفشه | wash dirt from between person 's " toe" "take off person 's shoe | Prerequisite Event Of |
| ۹ | «رقابت در مقابل فرد» و «سعی کنید به شل» | compete against person" "try to " "loose | LastSubevent Of |
| ۱۰ | «برو به خواب» و «نژدیکان چشم» | “go to sleep” “close person 's eye” | First Subevent Of |
| ۱۱ | «هوای در آسمان» | “Air” “in sky” | Location Of |
| ۱۲ | «فرد» و «کافی خواب» | “Person” “adequate sleep” | Desire Of |
| ۱۳ | «معاینه» و «دانستن دولت» | “have examination” “know person 's state” | Motivation Of |
| ۱۴ | «نوشیدن» و «خماری» | “Drinking” “hangover” | Effect Of |
| ۱۵ | «غار و غور از معده» و «را کاهش گرسنگی فرد را خود» | “growl from stomach” “diminish person 's own hunger” | Desirous Effect Of |
| ۱۶ | «پوست حیوانات» و «چرم» | “animal skin” “make leather” | Used For |
| ۱۷ | «برف» و «سعی در حذف کنید» | “Snow” “try to remove” | Capable Of Receiving Action |

جدول ۲. روابط تعریف شده در «کالسپت نت»

| طبقه | نوع رابطه | مثال |
|----------|-----------------------------|----------------------------------|
| چیزها | Part Of | ۱ «بیمه‌ی»، «هتل» |
| | Is A | ۲ «تابستان»، «زمان» |
| | Made Of | ۳ «آچار»، «فلز» |
| | Property Of | ۴ «امینم»، «همجنس‌گر» |
| | Defined As | ۵ «خدا»، «خالق» |
| عامل‌ها | Capable Of | ۶ «پدر، مادر»، «فرزنده» |
| رخدادها | Subevent Of | ۷ «نوشتن»، «شکستن نوک مداد» |
| | Prerequisite Event Of | ۸ «طلاق گرفتن»، «رفتن به دادگاه» |
| | Last Subevent Of | ۹ «ترک اتاق»، «خاموش کردن چراغ» |
| | First Subevent Of | ۱۰ «نوشتن مقاله»، «پژوهش» |
| فضایی | Location Of | ۱۱ «میراب»، «کلیسا» |
| محرك‌ها | Desire Of | ۱۲ «سک»، «توجه زیاد» |
| | Motivation Of | ۱۳ «تف کردن»، «نفرت از چیزی» |
| علی | Effect Of | ۱۴ «گیتارزدن»، «آرتروز» |
| | Desirous Effect Of | ۱۵ «حسادت» و «رقابت» |
| کارکردها | Used For | ۱۶ «خوردن سبزی»، «حفظ سلامت» |
| | Capable Of Receiving Action | ۱۷ «صلاح»، «مذاکره» |



شكل ۱. نمودار مربوط به کیفیت ترجمه به تفکیک موتور جستجو و رابطه (حداکثر امتیاز ۶۰)

فهرست منابع

- امیری، هادی، حسین حجت، و فرهاد ارومچیان. ۱۳۸۵. بررسی پیکره‌های مناسب برای برچسب‌زنی کلمات در زبان فارسی. ارائه شده در دوازدهمین کنفرانس بین‌المللی سالانه انجمن کامپیوترا ایران، تهران.
- شمفس فرد، مهرنوش، و احمد عبدالهزاده بارفروش. ۱۳۸۱. استخراج دانش مفهومی از متن با استفاده از الگوهای زبانی و معنایی. *مجله تازه‌های علوم‌شناسخی* ۱ (۱۲): ۴۸.
- مرادی، مهدی، بهرام وزیرنژاد، پروانه خسروی‌زاده، و هادی عبدالی قویدل. ۱۳۹۱. استخراج جملات عمومی از ویکی‌پدیای فارسی: تلاشی در جهت ساخت آنتولوژی دانش عرفی. چهارمین کنفرانس فناوری اطلاعات و دانش. بابل: انجمن فناوری اطلاعات و ارتباطات ایران و دانشگاه صنعتی نوشیروانی بابل.
- AleAhmad, Abolfazl, Hadi Amiri, Ehsan Darrudi, Masoud Rahgozar, and Farhad Oroumchian. 2009. Hamshahri: A Standard Persian Text Collection. *Knowledge-Based Systems* 22 (5): 382–387.
- Carlson, G. N. and F. J. Pelletier, eds. 1995. The Generic Book. Chicago: The University of Chicago Press.
- Descartes, R. 2008. Discourse on the Method for Reasoning Well and for Seeking Truth in the Sciences (The Gutenberg Project).
- Hearst, M. 1992. Automatic acquisition of hyponyms from large text corpora. In Proceedings of the 14th conference on computational linguistics, Nantes, France.
- Herdagdelen, A. 2010. Collecting common sense from text and people. Ph.D. Dissertation, University of Torento.
- Lenat, D. 1995. CYC: A large-scale investment in knowledge infrastructure. *Communications of the ACM* 38 (11).
- Lieberman, H. 2008. Usable AI requires commonsense knowledge. In Workshop on Usable Artificial Intelligence, ACM Conference on. Florence, Italy.
- _____, D. Smith, and A. Teeters. 2007. Common consensus: A web-based game for collecting commonsense goals. In Proceedings of the workshop on common sense and intelligent user interfaces held in conjunction with the 2007 international conference on intelligent user interfaces, Honolulu, USA.
- Lories, Danielle. 1991. *Des sensibles communs dans le 'De anima' d'Aristote*. Revue Philosophique. De Louvain (3) 89: 401-420.
- _____. 1998. *Le sens commun et le jugement du phronimos: Aristote et les stoiciens*. Louvain-la-Neuve, Editions Peeters.
- Luis von Ahn, Mihir Kedia, and Manuel Blum. 2006. Verbosity: a game for collecting common-sense facts. In Proceedings of ACM CHI 2006 Conference on Human Factors in Computing System, Quebec, Canada (pp. 75-78).
- McCarthy, J. 1959. Programs with common sense. In Proceedings of Teddington Conference on the Mechanization of Thought Processes, London, England (pp. 75–91).
- Shamsfard, M., A. Hesabi, H. Fadaei, N. Mansoory, A. Famian, S. Bagherbeigi, E. Fekri, M. Monshizadeh, and S. M. Assi. 2010. Semi automatic development of farsnet;the persian wordnet. In Proceedings of the 5th Global WordNet Conference, Mumbai, India.
- Sangun, P., Juyoung, K., Wooju, K.: A Framework for Ontology Based Rule Acquisition from Web Documents in Web Reasoning and Rule Systems (2007).
- Singh, P., T. Lin, E. T. Mueller, G. Lim, T. Perkins, and W. L. Zhu. 2002. Open Mind Common Sense: Knowledge acquisition from the general public. In Proceedings of First International Conference on ontologies, Databases, and Applications of Semantics for Large Scale Information Systems, Irvine, California.
- Suh, S., H. Halpin, and E. Klein. 2006. Extracting common sense knowledge from Wikipedia. In Proceedings of the ISWC-06 Workshop on Web Content Mining with Human Language Technologies, Athens, USA.

مهدی مرادی

متولد سال ۱۳۶۴، دارای مدرک تحصیلی کارشناسی ارشد زبان‌شناسی رایانشی از دانشگاه صنعتی شریف است. وی هم‌اکنون مدرس رایانه در گروه علوم تربیتی دانشگاه آزاد اسلامی زنجان است. هستان‌شناسی، استخراج رابطه و الگو، شناسایی خودکار نویسنده از جمله علایق پژوهشی ایشان هستند.

**بهرام وزیرنژاد**

متولد سال ۱۳۵۷، دارای مدرک دکتری مهندسی پزشکی از دانشگاه صنعتی امیرکبیر است. وی هم‌اکنون عضو هیئت علمی دانشگاه صنعتی شریف و مدیر آزمایشگاه پردازش گفتار و زبان است. پردازش زبان طبیعی و گفتار از جمله علایق پژوهشی ایشان هستند.

**محمد بحرانی**

متولد سال ۱۳۵۶، دارای مدرک دکتری در رشته هوش مصنوعی از دانشگاه صنعتی شریف است. وی هم‌اکنون عضو هیئت علمی گروه زبان‌شناسی رایانشی در مرکز زبان‌ها و زبان‌شناسی دانشگاه صنعتی شریف است. زبان‌شناسی رایانشی، پردازش زبان طبیعی، پردازش و بازشناسی گفتار و مدل‌سازی زبانی از جمله علایق پژوهشی ایشان هستند.



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی