

تن سازان، امیر؛ مهدوی، محمدامین (۱۳۹۶). استخراج فراداده‌های متنی از مقاله‌های علمی به زبان فارسی با مدل آماری CRF. پژوهش‌های نظری و کاربردی در علم اطلاعات و دانش‌شناسی، ۷(۱)، ۳۰۴-۳۲۱.



استخراج فراداده‌های متنی از مقاله‌های علمی به زبان فارسی با مدل آماری CRF

امیر تن سازان، دانشجوی کارشناسی ارشد مهندسی کامپیوتر - گرایش نرم افزار، دانشگاه بین المللی امام خمینی (ره) قزوین،
Ta.40.amir@gmail.com
محمد امین مهدوی، استادیار دانشکده فنی و مهندسی، دانشگاه بین المللی امام خمینی (ره) قزوین، mahdavi@eng.ikiu.ac.ir

تاریخ پذیرش: ۹۵/۸/۱۸

تاریخ دریافت: ۹۵/۶/۸

چکیده:

مقدمه: استخراج فراداده‌های متنی از مقاله‌های علمی به شکل دستی کار زمان‌بر و پرهزینه‌ای است. وجود تنوع در قالب‌های ساختاری مقالات علمی نیز به پیچیدگی مسئله می‌افزاید. بنابراین، استخراج خود کار فراداده‌های متنی از مقاله‌های علمی به عنوان یک مسئله مطرح است و از الگوریتم‌های مختلفی می‌توان برای استخراج فراداده‌ها استفاده کرد. هدف این مقاله ارائه یک چارچوب برای استخراج فراداده‌های متنی از مقاله‌های علمی به زبان فارسی است. در این پژوهش از مدل آماری سی‌آرف برای استخراج فراداده‌ها استفاده شده است.

دوفصلنامه (علمی پژوهشی)
پژوهش‌های نظری و کاربردی در علم
اطلاعات و دانش‌شناسی
شاپا (آنلاین): ۴۱۱۲-۲۵۳۸
<http://infosci.um.ac.ir>
سال ۷ (شماره ۱)
بهار و تابستان ۱۳۹۶

DOI: 10.22067/58517

روش‌شناسی: این مقاله یک پژوهش کاربردی است. در این مقاله با مطالعات کتابخانه‌ای و آزمایش سعی شده است یک چارچوب برای استخراج فراداده‌ها ارائه شود. چارچوب ارائه شده شامل شناسایی سرآیند و مراجع انگلیسی و فارسی مقاله است. از مدل آماری سی‌آرف برای استخراج فراداده‌ها از سرآیند و مراجع فارسی و انگلیسی استفاده شده است. با تعریف ویژگی‌های مختلف این مدل آماری قابل تغییر است. آزمایش این روش بروی صد مقاله از مجلات علمی - پژوهشی ایران درصد موفقیت آن را نشان می‌دهد. مدل آماری سی‌آرف در برچسبزنی متن نسبت به مدل‌های آماری دیگر مانند مدل مخفی مارکوف دقیق‌تر است. از سوی دیگر این مدل بر مبنای آمار و ریاضی برچسبزنی را انجام می‌دهد. استخراج فراداده‌ها از مقالات با

قالب‌های مختلف به کمک آمار نسبت به روش‌های مبتنی بر قانون نتایج بهتری را به دنبال دارد. بنابراین استفاده از مدل آماری سی آراف برای حل این مسئله مناسب است.

یافته‌ها: برای ارزیابی روش پیشنهاد شده از معیار ایف استفاده شده است. مقدار معیار ایف در این پژوهش برای هر توکن متنی محاسبه شده است. مقدار معیار ایف به شکل میانگین برای فراداده‌های سرآیند، فراداده‌های مراجع فارسی و فراداده‌های مراجع انگلیسی به ترتیب $96/19$ درصد، $93/87$ درصد و $94/75$ درصد است. نتایج این پژوهش با سه پژوهش مشابه در زبان انگلیسی مقایسه شده است. مقایسه میانگین نتایج بدست آمده نشان می‌دهد در فراداده‌های سرآیند نتایج پژوهش این مقاله بهتر از دو پژوهش انجام شده در زبان انگلیسی است. نتایج استخراج فراداده نویسنده در سرآیند در پژوهش‌های زبان انگلیسی بهتر است. برای فراداده چکیده در پژوهش زبان فارسی، نتایج بهتری بدست آمده است. مقایسه میانگین نتایج استخراج فراداده‌های مراجع، نشان می‌دهد پژوهش‌های زبان انگلیسی دقت بالاتری ارائه داده‌اند. نتایج استخراج فراداده مؤسسه در مراجع فارسی نسبت به فراداده‌های دیگر ضعیف‌تر است.

بحث و نتیجه‌گیری: بررسی نتایج بدست آمده نشان می‌دهد که عملکرد مدل آماری سی آراف برای استخراج فراداده‌ها خوب است. بیشترین دقت برای فراداده چکیده با معیار ایف برابر $99/6$ درصد است. این فراداده تعداد توکن بسیار بیشتری نسبت به بقیه فراداده‌ها دارد. دقت فراداده مؤسسه با معیار ایف برابر $80/95$ درصد کمتر از بقیه است. دو دلیل در کاهش دقت مؤثر است. تعداد این فراداده در پیکره متون نسبت به فراداده‌های دیگر کمتر است. علاوه بر این کلمات نحوی که در این فراداده به کار می‌رود، تنوع بیشتری دارد. در مراجع فارسی اسمای شهرها در فراداده‌های مکان و مؤسسه به کار می‌رود. این مسئله باعث می‌شود در برخی از موارد فراداده‌های مکان و مؤسسه به اشتباه تشخیص داده شوند. در زبان فارسی کلماتی که به شکل مشترک در فراداده‌های مختلف به کار می‌روند نسبت به زبان انگلیسی بیشتر است. برای مثال بسیاری از اسمای ایرانی که برای نام افراد به کار می‌رود با معانی دیگر در فراداده‌های دیگر استفاده می‌شود. این مسئله ممکن است باعث بروز خطأ شود. اکثر خطاهای به وجود آمده در استخراج فراداده‌ها مربوط به توکن‌هایی است که در مرز دو فراداده قرار دارند. تبدیل مقالات علمی فارسی با فرمت پی‌دی‌اف به فرمت متن در موارد زیادی با مشکل رو به رو است و از محدودیت‌های این پژوهش به شمار می‌آید. در این پژوهش مجموعه‌ای از صد مقاله علمی استفاده شد. افزایش تعداد مقاله‌های علمی و تنوع بیشتر مقالات برای آزمایش می‌تواند در نتیجه‌ی بدست آمده تاثیر مثبتی داشته باشد. مجموعه‌ای از ویژگی‌های متنی در الگوریتم‌های برچسب‌زنی سی آراف استفاده می‌شود. تغییر در این ویژگی‌ها می‌تواند موجب بهینه‌سازی روش شود.

کلیدواژه‌ها: استخراج فراداده‌های متنی، مقاله‌های علمی، پردازش زبان فارسی، الگوریتم CRF.

مقدمه

مقاله‌های علمی نقش مهمی در دنیای پژوهش دارند. آخرین یافته‌های علمی در حوزه‌های مختلف در مقاله‌ها منتشر می‌شود. دسترسی به یافته‌های جدید و پژوهش‌های روز از ملزمومات تحقیق در یک زمینه علمی است. دسترسی به پژوهش‌های جدید و مرتبط، به جستجو نیاز دارد. حجم انبوه مقاله‌ها و نبود فراداده‌های متنی مقالات، امکان جستجوی مقاله‌های علمی را دشوار می‌کند (Tkaczyk et al., 2015).

امروزه کتابخانه‌های دیجیتال و وب سایت‌های مجلات علمی و موتورهای جستجو، دسترسی و جستجوی هوشمند مقاله‌های علمی منتشر شده را برای پژوهشگران فراهم می‌کنند. این کتابخانه‌ها برای نمایه‌سازی مقاله‌های علمی به فراداده‌های متنی^۱ مقاله‌ها نیاز دارند (Tkaczyk et al., 2015). اطلاعاتی مانند نویسنده، عنوان، تاریخ، چکیده و نام انتشارات، فراداده‌های مقاله‌های علمی هستند. علاوه بر این، کتابخانه‌های دیجیتال برای نمایه‌سازی مراجع مقالات و نمایش مقاله‌های مرتبط به یک جستجو و محاسبه شاخص ارجاع^۲ به فراداده‌های مراجع نیاز دارند. نام نویسنده‌گان، عنوان، منبع، تاریخ و مؤسسه از جمله فراداده‌های مراجع در مقاله‌های علمی هستند (Guo and Jin, 2011b).

فراداده‌های مقاله را می‌توان در سه دسته قرار داد. دسته اول، فراداده‌های سرآیند^۳ مقاله که شامل اطلاعاتی مانند عنوان، چکیده و نویسنده‌گان است. دسته دوم، فراداده‌های مراجع که اطلاعاتی مانند نویسنده، عنوان، تاریخ و منبع در هر مرجع است. دسته سوم، فراداده‌های بدنه مقاله است. عنوان‌ین اصلی و فرعی مقاله از جمله فراداده‌های بدنه مقاله است. اکثر روش‌ها برای فراداده‌های سرآیند یا مراجع ارائه شده‌اند.

استخراج فراداده‌های متنی به شکل دستی کار هزینه‌بری است. از این‌رو ایجاد روش‌هایی برای استخراج خودکار فراداده‌های متنی مقالات ضروری است. این کار به دلیل تنوع فرمت مقالات و سبک‌های مختلف مراجع آنها چالش محسوب می‌شود (Guo and Jin, 2011a).

در این مقاله چارچوبی برای استخراج فراداده‌های متنی مقاله‌های علمی به زبان فارسی ارائه می‌شود. در بخش اول کارهایی که در گذشته در این زمینه در زبان‌های دیگر انجام شده است، مرور می‌شود. در بخش دوم الگوریتم برچسب‌زنی سی آر اف^۴ معرفی می‌شود. در بخش سوم روش پیشنهادی برای مقاله‌های فارسی بیان می‌شود. در بخش چهارم پیکره متنی که تست روش بر روی آنها انجام شده است و نتایج به دست آمده از تست روش بروی پیکره متن ارائه می‌شود.

مرواری بر کارهای گذشته

تاکنون روش‌های مختلفی برای استخراج فراداده‌های متنی در زبان انگلیسی ارائه شده است. این روش‌ها را می‌توان در دو دسته قرار داد. دسته اول روش‌های مبتنی بر قاعده و الگو و دسته دوم

1. metadata
2. Citation index
3. header
4. Conditional Random Field

روش‌های مبتنی بر یادگیری (Tkaczyk et al., 2015) در روش‌های مبتنی بر قاعده^۱ قوانینی تعریف می‌شود که با استفاده از آنها فراداده‌های متنی مقاله استخراج می‌شوند. گو و جین^۲ (۲۰۱۱a) چارچوبی را برای استخراج فراداده‌های سرآیند ارائه داده است. در این چارچوب برای استخراج فراداده‌ها، مجموعه قوانین مرتبط با ویژگی‌های فرمت و محتوای متن مقاله تعریف شده است. تکه‌های متنی مقاله و ویژگی‌های فرمت از تبدیل پی‌دی‌اف^۳ به فرمت ایکس‌ام‌ال^۴ فراهم شده است. جیوفریدا، شیک و یانگ^۵ (۲۰۰۰) روشی برای استخراج فراداده‌های سرآیند مقاله‌ها با فرمت پست اسکریپت^۶ ارائه کرده است. در این روش از ویژگی‌های ظاهری و بصری مقاله استفاده می‌شود. این ویژگی‌ها توسط ابزار پی‌اس تو تکست^۷ فراهم می‌شود. بیل^۸ و همکاران (۲۰۱۰) روشی مبتنی بر قانون برای استخراج عنوان ارائه داده است که در آن پس از تبدیل فرمت پی‌دی‌اف به فرمت ایکس‌ام‌ال از اندازه فونت و موقعیت مکانی متن برای شناسایی عنوان استفاده شده است. گو و جین (۲۰۱۱b) برای استخراج فراداده‌های مراجع مقاله روشی بر مبنای تطبیق الگو ارائه داد. در این روش براساس سبک‌های مختلف مرجع نویسی، مجموعه‌ای از الگوهای تعریف شده و با تطبیق الگو فراداده‌های هر مرجع استخراج می‌شود.

روش‌های مبتنی بر یادگیری برای استخراج فراداده‌های متنی در قالب طبقه‌بندی^۹ و برچسبزنی^{۱۰} دنباله قرار می‌گیرند. بخش‌هایی که برای طبقه‌بندی و برچسبزنی مورد استفاده قرار می‌گیرد، بلاک، سطر و کلمات مقاله است (Tkaczyk et al., 2015). کواسویچ^{۱۱} و همکارانش (۲۰۱۱) روشی را براساس الگوریتم اس‌وی‌ام^{۱۲} برای استخراج فراداده‌های سرآیند ارائه دادند. در این روش سطرهای مقاله طبقه‌بندی شده‌اند و ویژگی‌های مرتبط با کلمه و سطر برای طبقه‌بندی تعریف و استفاده شده است. از ابزار پی‌دی‌اف تو اچ تی ام‌ال^{۱۳} برای استخراج ویژگی‌های فرمت استفاده شده است. سیمور، مکالوم و روزنفلد^{۱۴}

-
1. Rule based
 2. Guo and Jin
 3. Portable Document Format
 4. XML
 5. Giuffrida, Sheck and Yang
 6. PostScript
 7. PsToText
 8. Beel
 9. Classification
 10. labeling
 11. Kovacevic
 12. Support Vector Machine
 13. Pdftohtml
 14. Seymore & McCallum & Rosenfeld

(۱۹۹۹) از الگوریتم مدل مخفی مارکوف برای برچسب‌زنی کلمات سرآیند مقاله و استخراج فراداده‌های متنی استفاده کرد. پنگ و مکالوم^۱ (۲۰۰۶) ایده به کار گیری الگوریتم سی آرف را برای استخراج فراداده‌های سرآیند و فراداده‌های مراجع را مورد بررسی قرار داد. در این روش، دنباله‌ای از کلمات سرآیند و دنباله‌ای از کلمات هر مرجع برچسب‌زنی شده‌اند. هان^۲ و همکارانش (۲۰۰۳) روشی براساس الگوریتم اس وی ام ارائه دادند. در این روش از طبقه‌بندی دو مرحله‌ای برای سطرهای مقاله استفاده می‌شود. برای استخراج ویژگی‌های طبقه‌بندی از خوشه‌بندی کلمات مقاله استفاده شده است. کانسیل، گیلز و کان^۳ (۲۰۰۸) از الگوریتم سی آرف برای استخراج فراداده‌های مراجع استفاده کرد. شناسایی و تفکیک مراجع قبل از پردازش توسط قواعد ساده انجام شده است. ژانگ^۴ و همکارانش (۲۰۱۱) از الگوریتم اس وی ام ساختار یافته^۵ برای پارس مراجع مقاله‌های علمی استفاده کرد. در این روش علاوه بر ویژگی‌های توکن از ویژگی‌های توکن‌های همسایه در برچسب‌زنی هر مرجع استفاده شده است. هتزнер^۶ (۲۰۰۸) روشی را برای استخراج فراداده‌های مراجع براساس مدل مخفی مارکوف ارائه داد.

تکاسزیک و همکارانش (۲۰۱۵) چارچوبی را برای استخراج فراداده‌های سرآیند و مراجع مقاله ارائه داد که کل متن مقاله را پردازش می‌کند. در این چارچوب از کتابخانه آی تکست^۷ و الگوریتم داک استرام^۸ برای قطعه‌بندی متن مقاله استفاده شده است. الگوریتم اس وی ام برای طبقه‌بندی بلوک‌های متنی مقاله و الگوریتم سی آرف برای استخراج فراداده‌های مراجع استفاده شده است. تفکیک مراجع نیز با استفاده از خوشه‌بندی نزدیک‌ترین همسایگی انجام شده است. کاندیاس^۹ (۲۰۱۱) چارچوبی را ارائه داد که در آن علاوه بر فراداده‌های سرآیند و مراجع، بدنه و عنوانین بخش‌های مقاله استخراج می‌شود. از الگوریتم سی آرف برای پردازش استفاده شده است. ابزار پی دی اف تو اچ تی ام ال برای استخراج ویژگی‌های فرمت در این روش استفاده شده است.

ابزارهای مختلفی در زبان انگلیسی برای استخراج فراداده‌ها از مقاله‌های علمی وجود دارد. برای مثال سی بی تو بیب^{۱۰} نرم‌افزاری رایگان برای استخراج داده‌های کتاب‌شناسی از مقاله‌های پی دی اف و

-
1. Peng and McCallum
 2. Han
 3. Councill, Giles and Kan
 4. Zhang
 5. Structural SVM
 6. Hetzner
 7. iText
 8. Docstrum
 9. Candeias
 10. Cb2bib

صفحات وب است. در این نرم‌افزار مجموعه‌ای از الگوهای از پیش تعریف شده برای استخراج فراداده‌ها استفاده می‌شود. فراداده‌های استخراج شده با فرمت بیب تکس^۱ ذخیره می‌شوند. امکان مدیریت فایل‌های کتاب‌شناسی و مقالات در این نرم‌افزار فراهم شده است (Cb2bib Overview, 2016). پارس سایت^۲ ابزار ابزار دیگری است که از الگوریتم سی آر اف برای استخراج فراداده‌های متنی از مراجع مقاله‌های علمی و استخراج ساختار مقاله‌های انگلیسی استفاده می‌کند. امکان ذخیره‌سازی فراداده‌های استخراج شده با فرمت‌های مختلف مانند بیب تکس^۳ و ایکس ام ال در این ابزار فراهم شده است (Parscit, 2016).

مدل آماری سی آر اف

مدل سی آر اف شکلی از مدل گرافی هدایت نشده^۴ است که توزیع خطی- لگاریتمی روی دنباله برچسب‌ها را براساس دنباله مشاهدات داده شده تعریف می‌کند. احتمال شرطی دنباله برچسب‌های $Y = Y_1 \dots Y_n$ و دنباله مشاهدات $x = x_1 \dots x_n$ به شکل زیر است (Wallach, 2004)

$$P(y|x, \lambda) = \frac{1}{Z(x)} \exp \left(\sum_j \sum_{i=1}^n \lambda_j f_j(y_{i-1}, y_i, x, i) \right) \quad (1)$$

در این رابطه $Z(x)$ ثابت نرمال‌سازی^۵ است. $f_j(y_{i-1}, y_i, x, i)$ تابع ویژگی برای برای بیان خصوصیات داده‌ها، مجموعه‌ای از ویژگی‌های مشاهدات را تعریف می‌کند. تابع ویژگی^۶ به دو شکل تابع حالت^۷ و تابع انتقال^۸ نمایش داده می‌شود. برای مثال یک تابع انتقال به شکل زیر تعریف می‌شود:

$$t_j(y_{i-1}, y_i, x, i) = \begin{cases} b(x, i) & \text{if } y_{i-1} = \text{abstract and } y_i = \text{keyword} \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

یک ویژگی دو یا چند مقداری است. برای مثال:

$$b(x, i) = \begin{cases} 1 & \text{if the observation at position } i \text{ is a word "abstract"} \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

تابع حالت فقط برچسب فعلی را در نظر می‌گیرد. $\lambda_1 \dots \lambda_n = \lambda$ پارامترهای تابع ویژگی هستند که از داده‌های یادگیری تخمین زده می‌شوند.

با مدل داده شده در معادله (۱) محتمل‌ترین دنباله برچسب‌ها برای دنباله مشاهدات به شکل زیر

است (Lafferty, McCallum and Pereira, 2001)

-
1. Bibtex
 2. ParsCit
 3. Bibtex
 4. Undirected graphical model
 5. Normalization constant
 6. Feature function
 7. State function
 8. Transition function

$$Y^* = \arg \max_y P(y|x) \quad (4)$$

این معادله با کمک برنامه‌نویسی دینامیک و الگوریتم ویتربی^۱ محاسبه می‌شود.

تخمین پارامترها در الگوریتم سی آراف با روش بیشترین درست‌نمایی^۲ انجام می‌شود. در صورتی که داده‌های یادگیری به شکل $\{(x_k, y_k) : k = 1, \dots, M\}$ باشد، حاصل ضرب معادله (۱) روی داده‌های یادگیری به عنوان تابعی از پارامترهای λ به عنوان تابع درست‌نمایی شناخته می‌شود و با $P(\{y^k\} | \{x^k\})$ نمایش داده می‌شود. روش بیشترین درست‌نمایی، پارامترهای λ را به گونه‌ای انتخاب می‌کند که الگوریتم درست‌نمایی با عنوان لگاریتم درست‌نمایی^۳ بیشترین مقدار را داشته باشد. برای الگوریتم سی آراف مقدار لگاریتم درست‌نمایی به شکل زیر تعریف می‌شود (Wallach, 2004):

$$L(\lambda) = \sum_k \left(\sum_j^n \lambda_j f_j(y_{i-1}, y_i, x_i) - \log(Z(x_k)) \right) \quad (5)$$

ماکریزم کردن رابطه (۵) معادله تساوی (۶) را به وجود می‌آورد. در این رابطه تعداد تجربی هر

ویژگی با تعداد مورد انتظار آن در مدل $P(y|x)$ تطبیق می‌یابد.

$$\sum_k \sum_i f_i(y_{i-1}, y_i, x_k, i) = \sum_k \sum_{y'} p(y' | x_k) \sum_i f_i(y'_{i-1}, y'_i, x_k, i) \quad (6)$$

برای حل رابطه بالا و تخمین پارامترها، الگوریتم مقیاس‌گذاری تکراری^۴ ارائه شده است. این الگوریتم سرعت کمی دارد. اثبات شده است که الگوریتم L-BFGS^۵ با سرعت بیشتری به ماکریزم دست دست می‌یابد. بنابراین برای تخمین پارامترها از این الگوریتم استفاده می‌شود (Peng and McCallum, 2006).

روش استخراج فراداده‌ها

در اینجا، مقالات علمی فارسی با فرمت متن به عنوان ورودی در نظر گرفته شده است؛ از این رو پردازش بر روی متن انجام می‌گیرد. به عبارتی، متن باید توسط ماشین قابل خواندن باشد. چارچوبی که برای استخراج فراداده‌های متی از مقاله‌های علمی پیشنهاد شده است، به سه مرحله قابل تقسیم است. در مرحله اول بخش سرآیند و بخش مراجع در مقاله شناسایی می‌شود. در مرحله دوم مراجع فارسی و انگلیسی از بخش مراجع شناسایی و تفکیک می‌شوند. پس از این کار مراجع مختلف مقاله شناسایی و از یکدیگر تفکیک می‌شوند. در مرحله سوم، سرآیند و مراجع مختلف فارسی و انگلیسی توسط سه

1. Viterbi

2. Maximum likelihood

3. log-likelihood

4. iterative Scaling

5. limited memory broyden fletcher goldfarb shanno

برچسب زن مجزای سی آر اف پردازش شده و فراداده‌های سرآیند، مراجع فارسی و مراجع انگلیسی استخراج می‌شود. شکل ۱ نمای کلی این چارچوب را نشان می‌دهد.

شناسایی سرآیند و مراجع

فراداده‌هایی که در روش پیشنهادی استخراج می‌شود، در سرآیند یا بخش مراجع مقاله قرار دارند؛ بنابراین، این دو بخش قبل از پردازش باید شناسایی شوند. برای این کار از ویژگی‌های متنی استفاده می‌شود. شروع متن مقاله ابتدای سرآیند مقاله است. انتهای سرآیند، شروع بخش مقدمه در مقاله است؛ بنابراین با کلمه کلیدی «مقدمه» این بخش شناسایی می‌شود. در برخی از مقاله‌های فارسی قبل از بخش مقدمه، عنوان و چکیده انگلیسی قرار گرفته است. در روش پیشنهادی، بخش انگلیسی جزئی از سرآیند نیست؛ بنابراین در این حالت از قاعده دیگری برای شناسایی سرآیند استفاده می‌شود. در این حالت با پیمایش متن مقاله و رسیدن به کلمه "abstract" قبل از مقدمه مقاله، پیمایش متن متوقف می‌شود و تا رسیدن به کلمات فارسی عقب گرد صورت می‌گیرد.

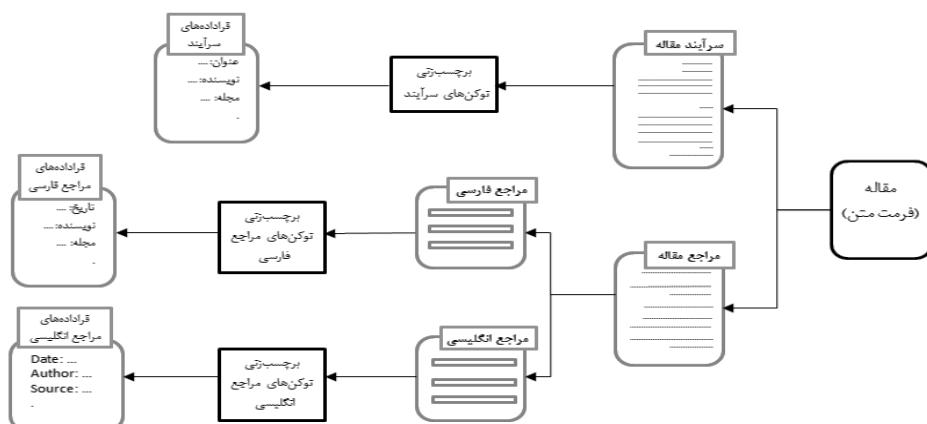
شناسایی ابتدای بخش مراجع با استفاده از کلمات کلیدی مانند «منابع» و «مراجع» و "References" انجام می‌شود. در صورتی که پس از مراجع، متن دیگری در مقاله نباشد، انتهای مقاله، انتهای مراجع نیز خواهد بود. در غیر این صورت چند حالت ممکن است رخ دهد. در حالت اول پس از مراجع بخش دیگری قرار دارد. در این حالت به کمک کلمات کلیدی عنوانین بخش‌های مقاله و طول سطرهای مقاله، انتهای مراجع شناسایی می‌شود. در حالت دوم در برخی از مقاله‌های فارسی، عنوان و چکیده انگلیسی پس از بخش مراجع قرار گرفته است. در این حالت پس از پیمایش سطرهای مقاله از شروع بخش مراجع با رسیدن به سطري شامل کلمه "abstract" عقب گرد انجام می‌شود. این عقب گرد تا رسیدن به سطري که با علامت نقطه پایان یافته است ادامه می‌یابد. علت این است که هر مرجعی در بخش مراجع با نقطه پایان یافته است.

مراحل تفکیک مراجع

بسیاری از مقاله‌های فارسی شامل مراجع انگلیسی و فارسی هستند. برای استخراج فراداده‌ها، این مراجع باید از یکدیگر تفکیک شوند. در مرحله اول مراجع فارسی و انگلیسی براساس الگو شناسایی و از یکدیگر تفکیک می‌شوند. برای این کار از تفاوت کاراکترهای انگلیسی و فارسی استفاده می‌شود. با این قاعده، در دو حالت امکان خطا وجود دارد. حالت اول زمانی است که سطري از بخش مراجع شامل کاراکترهای انگلیسی و فارسی باشد. در این حالت این سطر جزء مراجع فارسی است. زیرا گاهی در

مراجع فارسی کلمات انگلیسی به کار می‌رود. حالت دوم زمانی است که در مرجع فارسی یک سطر از کلمات انگلیسی وجود داشته باشد. در این حالت از تفاوت طول یک سطر با سطر قبلی اش در مراجع و کاراکترهای شروع مراجع مانند اعداد برای قرار دادن یک سطر در مراجع انگلیسی یا فارسی استفاده می‌شود.

پس از تفکیک مراجع انگلیسی و فارسی، مراجع مختلف از یکدیگر جدا می‌شوند. این کار با شناسایی سطرهای شروع یا پایان هر مرجع امکان‌پذیر است. مراجع مقاله‌های مختلف در دو دسته قرار می‌گیرند. دسته اول مراجعی هستند که با نشانه‌هایی مانند «[۱]» و «-» شروع می‌شوند. دسته دوم بدون نشانه‌اند. در دسته اول، نشانه‌های شروع برای تشخیص سطر اول هر مرجع به کار گرفته می‌شود. مقاله‌های فارسی به دو شکل یک ستونه و دو ستونه نوشته می‌شوند. برای دسته دوم، مراجع با توجه به طول سطر، یکی از دو حالت یک ستونه و دوستونه را خواهند داشت. در حالت یک ستونه تعداد سطر هر مرجع کمتر است و برخی از مراجع یک سطری هستند. در حالت دو ستونه تعداد سطرهای هر مرجع بیشتر از یک است.



شکل ۱. استخراج فراداده‌ها از مقاله‌های علمی فارسی

برای حالت دو ستونه از دو ویژگی برای تشخیص سطر انتهایی هر مرجع استفاده می‌شود. ویژگی اول این است که هر مرجع با علامت نقطه پایان می‌پذیرد. ویژگی دوم تفاوت طول یک سطر با سطر قبلی اش در مراجع است. برای حالت یک ستونه نیز دو ویژگی برای شناسایی سطر پایانی استفاده می‌شود. ویژگی اول پایان یافتن هر مرجع با علامت نقطه و ویژگی دوم اینکه سطر ابتدایی هر مرجع شامل نام نویسنده یا حالت مخفف نام است.

مواحد استخراج فراداده‌ها

سرآیند مقاله و هر یک از مراجع فارسی و انگلیسی که در مرحله قبل شناسایی شده است، در این مرحله ابتدا به مجموعه‌های از توکن‌ها تجزیه می‌شوند و سه مجموعه توکن تشکیل می‌شود. تجزیه تنها با فضای خالی انجام می‌شود. علاوه نگارشی به کلمه قبل از خود در بسیاری از موارد متصل هستند. کلماتی مانند «ها» که در زبان فارسی به شکل پیوسته و جدا نوشته می‌شوند، مشکلی را برای پردازش به وجود نمی‌آورند. برخی از حروف به دو شکل عربی و فارسی در توکن‌ها ظاهر می‌شوند. برای مثال دو «مجله» و «مجله». بنابراین قبل از پردازش حروف عربی به حروف فارسی تبدیل و توکن‌ها اصلاح می‌شوند.

سه برچسب‌زن سی آر اف برای استخراج فراداده‌های سرآیند، فراداده‌های مراجع فارسی و فراداده‌های مراجع انگلیسی استفاده می‌شود. فراداده‌های متنی براساس پیکره متن مقاله‌ها تعریف شده‌اند. برای هر برچسب‌زن، مجموعه‌ای از ویژگی‌ها و برچسب‌های مجزا تعریف شده است. مجموعه‌ای از ویژگی‌های تعریف شده برای برچسب‌زنی، از هر یک از توکن‌های مربوطه استخراج می‌شود. این مجموعه، بردار ویژگی^۱ نام دارد. هر الگوریتم برچسب‌زنی سی آر اف با دریافت مجموعه‌ای از بردارهای ویژگی و برچسب‌های متناظر، مدل یادگیری را ایجاد می‌کند. پس از یادگیری، داده‌های جدید با مدل ایجاد شده برچسب‌زنی می‌شوند.

فراداده‌های سرآیند شامل عنوان، نویسنده‌گان، اطلاعات نویسنده‌گان، چکیده، کلمات کلیدی، نام مجله، دوره، شماره و صفحه مجله و تاریخ است. این فراداده‌ها، برچسب‌های الگوریتم سی آر اف سرآیند هستند. این برچسب‌زن دنباله‌ای از کلمات سرآیند را برچسب‌زنی می‌کند. ویژگی‌هایی که برای برچسب‌زنی سرآیند تعریف شده‌اند، به شکل زیر است:

- توکن
- یک توکن با رقم شروع شده یا پایان یافته باشد. بر این اساس این ویژگی سه مقدار به خود می‌گیرد.
- توکن شامل علامت نقطه باشد.
- کاراکترهای توکن، انگلیسی یا فارسی باشند.
- توکن شامل علامت نگارشی باشد.
- توکن با الگوی ایمیل تطبیق پیدا کند.
- توکن یکی از کلمات عنوان بخش کلمات کلیدی مانند «کلیدواژه» باشد.

- توکن شامل کلمه «چکیده» باشد.
- توکن شامل یکی از کلماتی که اغلب در اطلاعات مجله به کار می‌رود، مانند «مجله» و «دوره» باشد.
- توکن شامل یکی از کلماتی که اغلب در اطلاعات نویسنده‌گان به کار می‌رود، مانند «استادیار» و «دانشجو» باشد.
- توکن شامل کلمات ماه و فصل مانند «بهار» و «اردیبهشت» یا الگوی ارقام سال مانند «۱۳۹۳» باشد.
- توکن برابر الگوی صفحات مانند «ص.» و «۱۰۰-۱۱۰» باشد.
- توکن فقط شامل عدد باشد.
- توکن یکی از نام‌های شهرهای ایران باشد.
- توکن یکی از نام‌های ایرانی مردان و زنان باشد.
- شماره سطری که توکن در آن قرار گرفته است.
- موقعیت توکن در سطر، این ویژگی یکی از سه مقدار ابتداء، وسط و انتهای سطر را به خود می‌گیرد.

فراداده‌های مراجع فارسی شامل نویسنده، عنوان، تاریخ، منبع، دوره، شماره، مؤسسه، صفحه و مکان است. فراداده منبع در مراجع می‌تواند نام مجله، نام انتشارات، نام کنفرانس و پایان‌نامه باشد. در الگوریتم سی آراف مراجع فارسی، یک برچسب مشترک برای فراداده دوره و شماره استفاده شده است. برای هر یک از فراداده‌های دیگر، یک برچسب مجزا تعریف شده است. دنباله توکن‌های هر مرجع فارسی توسط در این الگوریتم برچسب‌زنی می‌شود. ویژگی‌های تعریف شده برای این سی آراف شامل موارد زیر است:

- توکن
- توکن شامل کلمات ماه و فصل مانند «بهار» و «اردیبهشت» یا الگوی ارقام سال مانند «۱۳۹۳» باشد.
- توکن برابر الگوی صفحات مانند «ص.» و «۱۰۰-۱۱۰» باشد.
- توکن شامل ارقام یا حروف یا هر دو باشد.
- توکن برابر الگوی مخفف اسامی مانند «م.» باشد.
- توکن شامل علامت نگارشی باشد. این ویژگی شش مقدار را براساس نوع علامت نگارشی به خود می‌گیرد.
- توکن شامل کلماتی مانند «محله» باشد که در فراداده منبع به کار می‌رود.
- توکن شامل کلماتی که در مؤسسه به کار می‌رود مانند «دانشگاه» باشد.

- توکن شامل کلماتی که در دوره و شماره مجله به کار می‌رود مانند «سال» باشد.
- توکن فقط شامل الفبای انگلیسی باشد.
- توکن برابر اسمی یکی از شهرهای ایران باشد.
- توکن شامل یکی از نامهای مردان و زنان ایرانی باشد.
- موقعیت توکن در هر مرجع. برای این ویژگی پنج موقعیت مکانی براساس تعداد توکن‌های مرجع تعریف شده است.
- اولین توکن مرجع باشد.

فراداده‌های مراجع انگلیسی، عنوان، نویسنده، تاریخ، منبع، دوره، شماره، مکان و صفحه است. برای فراداده‌های دوره و شماره یک برجسب مشترک و برای هر یک از فراداده‌های دیگر، یک برجسب مجزا در الگوریتم سی آر اف مراجع انگلیسی در نظر گرفته شده است. دنباله توکن‌های هر مرجع انگلیسی توسط این الگوریتم برجسب‌زنی می‌شود. ویژگی‌های زیر برای این برجسب‌زنی تعریف شده است:

- توکن
- الگوی ارقام سال مانند "2009" و کلمات ماههای میلادی مانند "May"
- الگوی صفحات مانند "pp." و "page"
- شروع توکن با حروف بزرگ انگلیسی
- توکن شامل حروف، اعداد یا هر دو باشد.
- الگوی مخفف اسمی مانند "C." و "A.C."
- توکن شامل کلمات et al. باشد.
- توکن شامل علائم نگارشی باشد. براساس نوع علامت نگارشی این ویژگی شش مقدار مختلف را دریافت می‌کند.
- مجموعه کلماتی مانند "journal" که در فراداده منبع اغلب به کار می‌رود.
- مجموعه کلماتی مانند "volume" که در فراداده دوره و شماره اغلب به کار می‌رود.
- مکان توکن در مرجع. این ویژگی براساس تعداد توکن مرجع محاسبه می‌شود و پنج مقدار دارد. پس از اینکه سه الگوریتم سی آر اف، توکن‌های سرآیند، مراجع فارسی و مراجع انگلیسی را برجسب‌زنی کردند، توکن‌های برجسب خورده همسایه که برجسب یکسان دارند، به یکدیگر متصل می‌شوند و فراداده‌ها را تشکیل می‌دهند.

تفکیک دوره و شماره

توکن‌هایی که در برچسبزنی مراجع انگلیسی و فارسی برچسب دوره را دریافت کرده‌اند، شامل دو فراداده دوره و شماره هستند. پس از برچسبزنی و اتصال توکن‌های همسایه، این دو فراداده براساس الگوهای متی، ارقام و علائم نگارشی شناسایی می‌شوند. در مراجع فارسی، الگوی «دوره (شماره:)»، کلمات «سال»، «دوره»، «جلد»، «شماره»، «پاپی»، مخفف هر یک از این کلمات مانند «س» و در مراجع انگلیسی الگوی "Number" و "Volume" و "No" و "Vol" و "Issue" به کار برد می‌شود.

آزمایش

برای تست روش پیشنهادی، ۱۰۰ مقاله مجلات مختلف علمی- پژوهشی ایران انتخاب شده است. برای این کار مجموعه‌ای از مجلات علمی که در سامانه ارزیابی نشریات وزارت علوم ثبت شده‌اند استفاده شده است. مجموعه‌ای از مقاله‌ها به شکل تصادفی از این مجلات انتخاب شده‌اند. انتخاب مقاله‌ها به شکلی انجام شده است که تنوع فرمت در پیکره متن و وجود داشته باشد. این مقاله‌ها در حوزه‌های علمی مختلف هستند و به شکل رایگان در وب سایت مجلات در دسترس هستند. تعداد مقاله‌های انتخاب شده مشابه پژوهش‌هایی در زبان انگلیسی مانند کواسویچ و همکارانش (۲۰۱۱) است که برای ارزیابی به شکل دستی پیکره متن را برچسبزنی کرده‌اند. مقاله‌های جمع‌آوری شده به فرمت متن تبدیل شده‌اند. سرآیند مقاله‌ها با فراداده‌های این بخش برچسبزنی شده‌اند. مجموع ۱۰۰ سرآیند و ۳۴۲ مرجع فارسی و ۴۰۰ مرجع انگلیسی فراداده‌های آنها برچسبزنی شده‌اند. در مجموع این روش پنج بار تست انجام شده است. برای تست، برچسبزنی و استفاده شده‌اند.

تست با روش اعتبارسنجی عرضی پنج قسمتی^۱ اجرا شده است. در این روش پیکره متن به پنج قسمت مساوی تقسیم و پنج بار تست انجام می‌شود. در هر بار تست، یکی از پنج بخش پیکره متن برای تست و چهار بخش دیگر برای یادگیری و ایجاد مدل در الگوریتم برچسبزنی استفاده می‌شود. در نهایت برای ارزیابی، میانگین نتایج پنج تست محاسبه می‌شود. برای پیاده‌سازی الگوریتم برچسبزنی از کتابخانه سی آر اف پلاس پلاس^۲ استفاده شده است. تخمین پارامترها در این کتابخانه با الگوریتم BFGS-L انجام می‌شود.

معیارهای ارزیابی

1. five-fold cross validation

2. CRF++

برای ارزیابی از سه معیار دقت^۱، فراخوانی^۲ و معیار اف^۳ استفاده شده است. این ارزیابی برای توکن‌های برچسب‌زده اندازه‌گیری شده است؛ بنابراین به شکل زیر معیارهای ارزیابی تعریف می‌شوند:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (۷) \quad \text{Recall} = \frac{TP}{TP+FN} \quad (۸)$$

$$\text{F-Measure} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (۹)$$

در رابطه‌های بالا TP^4 تعداد توکن‌هایی است که برچسب آنها عنوان یا نویسنده یا فراداده‌های دیگر بوده و درست پیش‌بینی شده است. FP^5 تعداد توکن‌هایی نامربوط به داده است که برچسب آنها که اشتباه نسبت داده شده است. برای مثال هنگام بررسی عنوان، یک توکن جزو نویسنده است و به اشتباه برچسب عنوان را دریافت کرده است. FN^6 تعداد توکن‌های مربوط به داده است که به اشتباه برچسب دیگری را دریافت کرده‌اند. برای مثال هنگام ارزیابی عنوان، یک توکن که جزو توکن‌های عنوان بوده، به اشتباه برچسب چکیده را دریافت کرده است.

نتایج

نتایج به دست آمده برای فراداده‌های سرآیند در جدول ۱ نمایش داده شده است. دقت استخراج تمامی فراداده‌ها در سطح خوبی است. بیشترین دقت برای فراداده چکیده با معیار اف برابر ۹۹/۶ درصد است. این فراداده تعداد توکن بسیار بیشتری نسبت به بقیه فراداده‌ها دارد. فراداده نویسنده با معیار اف برابر ۹۴/۳ درصد کمترین دقت را دارد. نتایج به دست آمده برای فراداده‌های مراجع فارسی در جدول ۲ آمده است.

نتایج نشان می‌دهد دقت اکثر فراداده‌ها بالای ۹۰ درصد است. دقت فراداده مؤسسه با معیار اف برابر ۸۰/۹۵ درصد کمتر از بقیه است. تعداد این فراداده در پیکره متون نسبت به فراداده‌های دیگر کمتر است. علاوه بر این کلمات نحوی که در این فراداده به کار می‌رود، تنوع بیشتری دارد. این دو عامل در پایین آمدن دقت مؤثر است. فراداده مکان بعد از مؤسسه دقت پایینی نسبت به فراداده‌های دیگر دارد.

-
1. Precision
 2. Recall
 3. F-measure
 4. True positive
 5. False positive
 6. False negative

در مراجع فارسی اسامی شهرها در فراداده‌های مکان و مؤسسه به کار می‌رود. این مسئله باعث می‌شود در برخی از موارد فراداده‌های مکان و مؤسسه به اشتباه تشخیص داده شوند. بهترین نتیجه برای فراداده تاریخ با معیار اف برابر ۹۸/۳۷ درصد به دست آمده است.

جدول ۱. نتایج برچسبزنی فراداده‌های سرآیند مقاله

فراداده	دقت	فراخوان	معیار اف
عنوان	۹۶/۵۸	۹۶/۸۲	۹۶/۶۷
نویسنده	۹۵/۷۳	۹۳/۱۸	۹۴/۳۰
اطلاعات نویسنده‌گان	۹۷/۹۹	۹۷/۰۹	۹۷/۵۲
چکیده	۹۹/۵۲	۹۹/۶۹	۹۹/۶۰
كلمات کلیدی	۹۶/۴۹	۹۶/۵۴	۹۶/۴۲
مجله	۹۴/۲۹	۹۸/۶۶	۹۶/۱۳
دوره	۹۹/۵۳	۹۶/۹۵	۹۸/۲۰
شماره	۹۸/۰۹	۹۵/۵۹	۹۶/۷۷
صفحه	۹۷/۷۷	۹۴/۳۵	۹۵/۶۹
تاریخ	۹۷/۱۷	۹۸/۱۹	۹۷/۶۴
کل فراداده‌ها	۹۷/۳۱	۹۶/۷۰	۹۶/۸۹

جدول ۲. نتایج برچسبزنی فراداده‌های مراجع فارسی مقاله

فراداده	دقت	فراخوان	معیار اف
عنوان	۹۶/۳۳	۹۸/۸۰	۹۷/۵۲
نویسنده	۹۸/۹۶	۹۸/۵۳	۹۸/۷۲
تاریخ	۹۷/۹۵	۹۸/۸۳	۹۸/۳۷
منبع	۹۳/۳۸	۹۱/۲۹	۹۲/۲۳
دوره	۹۸/۴۷	۹۷/۱۸	۹۷/۷۹
صفحه	۹۷/۵۵	۹۸/۰۹	۹۷/۷۷
مؤسسه	۸۳/۳۴	۷۹/۱۴	۸۰/۹۵
مکان	۹۲/۰۷	۸۳/۸۶	۸۷/۶۲
کل فراداده‌ها	۹۴/۷۵	۹۳/۲۱	۹۳/۸۷

جدول ۳. نتایج برچسبزنی فراداده‌های مراجع انگلیسی مقاله

فراداده	دقت	فراخوان	معیار اف

عنوان	۹۶/۱۰	۹۸/۲۷	۹۷/۱۵
نویسنده	۹۷/۹۰	۹۹/۳۰	۹۸/۵۸
تاریخ	۹۸/۳۳	۹۶/۹۱	۹۷/۶۰
منبع	۹۳/۲۳	۹۲/۲۰	۹۲/۶۵
دوره	۹۷/۶۳	۹۸/۰۱	۹۷/۸۰
صفحه	۹۹/۳۱	۹۸/۷۹	۹۹/۰۳
مکان	۸۸/۱۵	۷۴/۸۲	۸۰/۴۹
کل فراداده‌ها	۹۵/۸۰	۹۴/۰۴	۹۴/۷۵

در زبان فارسی کلماتی که به شکل مشترک در فراداده‌های مختلف به کار می‌روند نسبت به زبان انگلیسی بیشتر است. برای مثال بسیاری از اسمای ایرانی که برای نام افراد به کار می‌رود با معانی دیگر در فراداده‌های دیگر استفاده می‌شود. این مسئله ممکن است باعث بروز خطا شود. اکثر خطاهای به وجود آمده در استخراج فراداده‌ها مربوط به توکن‌هایی است که در مرز دو فراداده قرار دارند. نتایج استخراج فراداده‌های مراجع انگلیسی در جدول ۳ آمده است. فراداده صفحه از دقت بالاتری برخوردار است. فراداده صفحه تنوع کمتری دارد.

جدول ۴. مقایسه نتایج برچسب‌زنی فراداده‌های سرآیند مقاله

فراداده	این مقاله (سرآیند فارسی)	CRF (Peng and McCallum, 2006)	SVM (Han et al., 2003)
عنوان	۹۶/۶۷	۹۷/۱۰	۹۶/۵
نویسنده	۹۴/۳۰	۹۷/۵۰	۹۷/۲
اطلاعات نویسنده‌گان	۹۷/۵۲	۹۷	۹۳/۸
چکیده	۹۹/۶۰	۹۹/۷	۹۳/۸
کلمات کلیدی	۹۶/۴۲	۸۸/۸	۸۸/۵
تاریخ	۹۷/۶۴	۹۵	۹۰/۲
کل فراداده‌ها	۹۷/۰۲	۹۵/۸۵	۹۳/۳

جدول ۵. مقایسه نتایج برچسب‌زنی فراداده‌های مراجع مقاله

فراداده	این مقاله (مراجع انگلیسی)	این مقاله (مراجع فارسی)	CRF (Councill, Giles and Kan, 2008)	CRF (Peng and McCallum, 2006)
عنوان	۹۷/۵۲	۹۷/۱۵	۹۷	۹۸/۳
نویسنده	۹۸/۷۲	۹۸/۵۸	۹۹	۹۹/۴
تاریخ	۹۸/۳۷	۹۷/۶۰	۹۹	۹۸/۹
منبع	۹۲/۲۳	۹۲/۶۵	۹۱	۹۱/۳
دوره	۹۷/۷۹	۹۷/۸۰	۹۶	۹۷/۸

صفحه	کل فراداده‌ها	۹۷/۷۷	۹۹/۰۳	۹۸/۶	۹۸
مؤسسه	۸۰/۹۵	-	۸۰/۴۹	۸۷/۲	۸۹
مکان	۸۷/۶۲	۸۰/۴۹	۸۷/۲	۹۴	۹۳
کل فراداده‌ها	۹۳/۸۷	۹۴/۷۵	۹۵/۶۸	۹۵/۲۵	

نتایج روشی که در این مقاله ارائه شده است، با سه پژوهشی که در زبان انگلیسی انجام شده است، مقایسه شده است. جدول ۴ نتایج مقایسه فراداده‌های سرآیند و جدول ۵ نتایج مقایسه فراداده‌های مراجع را نشان می‌دهد. برای مقایسه از معیار ارف استفاده شده است. فراداده‌هایی که در این مقاله و کارهای دیگر مشترک هستند، در نظر گرفته شده است. برای فراداده منبع در پژوهش‌های زبان انگلیسی، از نتایج فراداده مجله استفاده شده است.

مقایسه میانگین نتایج به دست آمده نشان می‌دهد در فراداده‌های سرآیند نتایج پژوهش این مقاله بهتر از عملکرد دو پژوهش انجام شده در زبان انگلیسی است. نتایج استخراج فراداده نویسنده در پژوهش‌های زبان انگلیسی بهتر است. برای فراداده چکیده در پژوهش‌های انگلیسی زبان، نتایج ضعیف‌تری به دست آمده است. مقایسه میانگین نتایج استخراج فراداده‌های مراجع، نشان می‌دهد پژوهش‌های زبان انگلیسی با اختلاف یک تا دو درصد بهتر است. نتایج استخراج فراداده مؤسسه نسبت به فراداده‌های دیگر ضعیف‌تر است. مقایسه نتایج به دست آمده حاکی از آن است که اختلاف نتایج در اکثر فراداده‌ها بین یک تا دو درصد است.

نتیجه

استخراج فراداده‌های متنی از مقالات علمی برای نمایه‌سازی مقالات لازم است. این کار به دلیل نوع مقاله‌ها یک مسئله به شمار می‌آید. در این مقاله یک چارچوب برای استخراج فراداده‌های متنی از مقاله‌های علمی فارسی پیشنهاد شد. این چارچوب شامل شناسایی سرآیند و بخش مراجع، تفکیک مراجع و پردازش سرآیند و هر یک از مراجع است. فراداده‌های سرآیند و فراداده‌های مراجع فارسی و مراجع انگلیسی در این چارچوب استخراج شد. پردازش سرآیند و هر یک از مراجع توسط الگوریتم برچسب‌زنی سی آر اف انجام گرفت.

به طور میانگین مقدار معیار ارف در سطح توکن برای فراداده‌های سرآیند ۹۶/۸۹ درصد، برای فراداده‌های مراجع فارسی ۹۳/۸۷ درصد و برای فراداده‌های مراجع انگلیسی ۹۴/۷۵ درصد به دست آمده است. نتایج به دست آمده نشان می‌دهد که الگوریتم برچسب‌زنی سی آر اف برای استخراج فراداده‌های

متنی از مقاله‌های فارسی عملکرد خوبی دارد. افزایش تعداد مقاله‌ها در پیکره متون می‌تواند خطرا کاهش دهد.

نتایج این مقاله با نتایج سه پژوهش انجام شده در زبان انگلیسی مقایسه شده است. نتایج به دست آمده نشان می‌دهد که عملکرد پژوهش این مقاله در زبان فارسی و پژوهش‌های انگلیسی زبان در استخراج فراداده‌ها، به یکدیگر نزدیک است.

کتابنامه

- Beel, J., Gipp, B., Shaker, A., & Friedrich, N. (2010). SciPlore Xtract: Extracting Titles from Scientific PDF Documents by Analyzing Style Information (Font Size). *Proceedings of the 14th European Conference on Digital Libraries*. Glasgow.
- Candeias, R. (2011). Metadata Extraction from Scholarly Articles. *cb2bib overview*. (2016). Retrieved 2015, from http://www.molspaces.com/d_cb2bib-overview.php.
- Councill, I. G., Giles, C. L., & Kan, M. Y. (2008). ParsCit: an Open-source CRF Reference String Parsing Package. *In LREC*, 8, 661-667.
- Giuffrida, G., Sheck, E., & Yang, J. (2000). KnowledgeBased Metadata Extraction from PostScript Files. *Proceedings of the fifth ACM conference on Digital libraries* (pp. 77-84). San Antonio, TX, USA: ACM.
- Guo, Z., & Jin, H. (2011a). A Rule-based Framework of Metadata Extraction from Scientific Papers. *10th International Symposium on Distributed Computing and Applications to Business, Engineering and Science* (pp. 400-404). Wuxi: IEEE.
- Guo, Z., & Jin, H. (2011b). Reference Metadata Extraction from Scientific Papers. *12th International Conference on Parallel and Distributed Computing, Applications and Technologies* (pp. 45-49). Gwangju: IEEE.
- Han, H., Giles, C. L., Manavoglu, E., Zha, H., Zhang, Z., & Fox, E. A. (2003). Automatic document metadata extraction using support vector machines. *Digital Libraries, 2003. Proceedings. 2003 Joint Conference on* (pp. 37-48). IEEE.
- Hetzner, E. (2008). A simple method for citation metadata extraction using hidden markov models. *In Proceedings of the 8th ACM/IEEE-CS joint conference on Digital libraries* (pp. 280-284). ACM.
- Kovacevic, A., Ivanovic, D., Milosavljevic, B., Konjovic, Z., & Surla, D. (2011). Automatic Extraction of Metadata from Scientific Publications for CRIS Systems. *Electronic Library and Information Systems*, 45 (4), 376-396.
- Lafferty, J., McCallum, A., & Pereira, F. (2001). Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data. *Proceedings of the eighteenth international conference on machine learning*. 1, pp. 282-289. USA: Morgan Kaufmann.
- ParsCit: An open-source CRF Reference String and Logical Document Structure Parsing Package*. (2016). Retrieved 2015, from <http://aye.comp.nus.edu.sg/parsCit/>.
- Peng, F., & McCallum, A. (2006). Information extraction from research papers using conditional random fields. *Information processing & management*, 42 (4), 963-979.
- Seymore, K., McCallum, A., & Rosenfeld, R. (1999). Learning hidden Markov model structure for information extraction. *AAAI-99 Workshop on Machine Learning for Information Extraction*.
- Tkaczyk, D., Szostek, P., Dendek, P., Fedoryszak, M., & Bolikowski, L. (2015). CERMINE: automatic extraction of structured metadata from scientific literature. *IJDAR*, 18 (4), 317-335.
- Wallach, H. (2004). *Conditional Random Fields: An Introduction*. University of Pennsylvania CIS Technical Report.

Zhang, X., Zou, J., Le, D., & Thoma, G. R. (2011). A structural SVM approach for reference parsing. *BMC bioinformatics*, 12 (3), 479-484.