

Detecting Similarity in Paraphrased Persian Texts using Semantic and Probabilistic Methods

Nasrollah Pakniat*

PhD in Mathematics; Assistant Professor; Iranian Research Institute for Information Science and Technology (IranDoc);
Email: pakniat@irandoc.ac.ir

Azadeh Mohebi

PhD in System Design Engineering; Assistant Professor;
Iranian Research Institute for Information Science and Technology (IranDoc) Email: mohebi@irandoc.ac.ir

Received: 04, Mar. 2018 Accepted: 15, Sep. 2018

Iranian Journal of
Information
Processing and
Management

Iranian Research Institute
for Information Science and Technology
(IranDoc)
ISSN 2251-8223
eISSN 2251-8231
Indexed by SCOPUS, ISC, & LISTA
Vol. 34 | No. 4 | pp. 1823-1848
Summer 2019
<https://doi.org/10.35050/JIPM010.2019.023>

Abstract: Plagiarism detection is the process of locating instances of plagiarism within a work or a document. The main component of a plagiarism detection system is its text alignment algorithm aiming at detecting paraphrased passages of texts in a suspicious document, using a small set of candidate source documents. As text alignment algorithms are highly language-dependent, thus the numerous existing algorithms for other languages other than Persian cannot be employed for Persian plagiarism detection purposes. There are different text alignment algorithms for Persian texts, while most of them are only able to detect exactly identical passages shared between texts. However, in many cases of plagiarism detection we are coping with the problem of finding similar passages that are already paraphrased. In this paper, we propose two new text alignment algorithms which are able to detect paraphrased texts in Persian language. The first one is a semantic algorithm that employs a dictionary to detect paraphrased sentences and the second one is a probabilistic algorithm that uses the statistical information obtained from a large corpus of Persian texts to detect similar texts. Compared to other existing semantic text alignment algorithms, the proposed algorithms use different measures to check the similarity between the text sentences. Furthermore, the probabilistic algorithm is the first probabilistic text alignment algorithm proposed for the Persian language. Moreover, while all existing text alignment algorithms check the similarity between any two sentences of the text separately, the proposed algorithms consider the similarity neighboring sentences in the text as well. The implementation results indicate that while the quality of both algorithms in detecting paraphrased texts is high



* Corresponding Author

enough and almost the same as each other, the proposed probabilistic method is more efficient than the proposed semantic algorithm in terms of computation time.

Keywords: Plagiarism, Semantic Text Alignment, Probabilistic Text Alignment, Paraphrased Texts

همانندجويي در متون فارسي

بازنويسى شده با استفاده از روش های معنایي و احتمالاتی

نصرالله پاکنیت

دکتری ریاضی؛ استادیار؛
پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)؛
پدیدآور رابط pakniat@irandoc.ac.ir

آزاده محبی

دکتری؛ مهندسی طراحی سیستم‌ها؛ استادیار؛
پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)؛
mohebi@irandoc.ac.ir



دربافت: ۱۳۹۶/۱۲/۱۳ | پذیرش: ۱۳۹۷/۰۶/۲۴ | مقاله برای اصلاح به مدت ۴۹ روز ترد پدیدآوران بوده است.

نشریه علمی | رتبه بین المللی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایرانداک)

شای (چاپی)
۲۲۵۱-۸۲۲۳

شای (الکترونیکی)
۲۲۵۱-۸۲۲۱

نمایه در SCOPUS, ISC, و
jipm.irandoc.ac.ir

دوره ۳۴ | شماره ۴ | صص ۱۸۴۸-۱۸۲۳
تابستان ۱۳۹۸

<https://doi.org/10.35050/JIPM010.2019.023>



چکیده: همانندجويي ابزاری است که از آن برای تشخيص سرقت علمی / ادبی استفاده می شود. هدف در یک روش همانندجويي، تشخيص تمام قسمت های همانند موجود در یک متن مشکوک با توجه به تعدادی متن منبع احتمالی است. روش های زیادی برای همانندجويي ارائه شده، اما از یک طرف، استفاده از روش های همانندجويي موجود برای سایر زبان ها به منظور همانندجويي در زبان فارسي مناسب نیست و از طرف دیگر، اغلب روش های ارائه شده برای همانندجويي در زبان فارسي قادر به تشخيص متون بازنويسي شده نیستند. با توجه به این مهم، در این مقاله دو روش همانندجويي جدید با هدف تشخيص متون فارسي بازنويسي شده ارائه خواهد شد. روش شناسی پژوهش بر اساس مطالعه منابع و مستندات معتبر علمی در این خصوص و روش کتابخانه ای است. روش اول پیشنهادی روشی معنایي است و از لغت نامه جهت بررسی همانندی جملات متون استفاده می کند. روش دوم پیشنهادی روشی احتمالاتی است و از اطلاعات آماری به دست آمده از پیگرهاي عظيم از متون برای همانندجويي استفاده می کند. روش معنایي پیشنهادی در مقایسه با روش های معنایي موجود از معیارهای جدید تری برای بررسی همانندی متون استفاده کرده و روش احتمالاتی پیشنهادی اولین روش همانندجويي احتمالاتی ارائه شده برای زبان فارسي است. علاوه بر این، در حالی که در سایر روش های موجود، همانندی هر دو جمله از متون مورد نظر به صورت مستقل بررسی می شود، در روش های

پیشنهادی همانندی جملات همسایه نیز در بررسی همانندی دو جمله در نظر گرفته شده است. نتایج پیاده‌سازی و آزمایشات صورت گرفته بر روی روش‌های پیشنهادی نشان می‌دهد که در حالی که هر دو روش از کیفیت مناسب و تقریباً یکسانی برخوردار هستند، روش همانندجوی احتمالاتی پیشنهادی بسیار کارتر بوده و زمان مورد نیاز برای همانندجویی با استفاده از آن به طور متوسط برابر با $\frac{3}{8}$ درصد زمان مورد نیاز توسط الگوریتم همانندجوی معنایی پیشنهادی است.

کلیدواژه‌ها: تشخیص سرقت علمی، همانندجویی معنایی، همانندجویی احتمالاتی، متون بازنویسی شده

۱. مقدمه

سرقت علمی عبارت است از استفاده غیرمجاز یا تقلید نزدیک از ایده‌ها و نگارش شخصی دیگر و ارائه آن به عنوان کار خود (Hannabuss 2001). همانندجویی ابزاری است که از آن برای تشخیص سرقت علمی استفاده می‌شود. هر روش همانندجویی از سه فرایند تشکیل شده است: ۱) بازیابی منبع، ۲) تطبیق متن، و ۳) پردازش نهایی. هدف در فرایند بازیابی منبع، با فرض در اختیار داشتن یک متن علمی مشکوک، بازیابی تمام منابعی است که از متن آن‌ها در نگارش متن مشکوک استفاده شده است؛ به طوری که هزینه‌های بازیابی کمینه شود. در فرایند تطبیق متن با ورودی یک متن مشکوک و یک متن منبع احتمالی، این متون به واحدهایی (مانند پاراگراف، جمله یا دنباله‌های چندتایی از لغات و کاراکترها) تقسیم‌بندی شده و همانندی هر دو واحد مورد بررسی واقع می‌شود. هدف این فرایند مشخص نمودن همه قسمت‌های متن مشکوک است که با استفاده از متن منبع بازنویسی شده‌اند. هدف در فرایند پردازش نهایی، با ورودی متن مشکوک انجام بررسی‌های بیشتر برای ویرایش‌های نهایی در قسمت‌هایی است که با متن منبع احتمالی مشابه تشخیص داده شده است (Potthast et al. 2013).

در عمل، اولین فرایند همانندجویی یعنی بازیابی منبع با استفاده از روش‌های بازیابی اطلاعات انجام می‌شود. برای این منظور، از روش‌های معمول بازیابی اطلاعات استفاده می‌شود که می‌توانند بر اساس عملگرهای بولین، روش‌های مبتنی بر مدل‌های فضای برداری، روش‌های مبتنی بر هش و اثر انگشت، و روش‌های مبتنی بر الگوریتم‌های Word2Vec و doc2Vec (Alzahrani, Salim and Abraham 2012; Mikolov et al. 2013; Le and Mikolov 2014) باشند. با توجه به این مهم، در سالیان اخیر این فرایند از مسئله همانندجویی

جدا شده و تنها فرایندهای تطبیق متن و پردازش نهایی به عنوان فرایندهای همانندجويی در نظر گرفته می‌شوند. در این پژوهش تمرکز روی ارائه روشی برای همانندجويی متون علمی نگارش شده به زبان فارسی است. روش‌ها و نرم‌افزارهای زيادي برای همانندجويی متون نوشته شده و در زبان‌های مختلف ارائه شده است که بسیاری از آن‌ها وابسته به قواعد و ویژگی‌های خاص هر زبان هستند و نمی‌توان از آن‌ها به راحتی برای زبان فارسی استفاده کرد. از طرف دیگر، اغلب تحقیقات انجام‌شده در زمینه همانندجويی در متون فارسی تنها قادر به تشخیص قسمت‌های دقیقاً یکسان از متن بوده و نمی‌تواند قسمت‌های بازنويسي شده از متن را تشخیص دهد. بنابراین، مسئله‌ای که پژوهش حاضر به حل آن می‌پردازد، یافتن روشی است که از طریق آن بتوان همانندی متون بازنويسي شده را محاسبه نمود. با توجه به این مهم، در این مقاله دو روش همانندجويی جدید برای زبان فارسی با هدف تشخیص متون بازنويسي شده ارائه می‌شود. روش اول پیشنهادی، يك روش معنائي است که برای بررسی همانندی دو قسمت مختلف متن از لغت‌نامه استفاده می‌کند. در مقایسه با سایر روش‌های معنائي ارائه شده برای زبان فارسی، در این روش از معیارهای جدیدتری برای بررسی همانندی استفاده می‌شود. علاوه بر اين، در این روش، همانندی دو واحد مختلف متن به صورت مجزا بررسی نمی‌شود، بلکه در بررسی همانندی اين دو واحد، همانندی واحدهای نزديک به آن‌ها در متن مشکوک و متن منبع احتمالي نيز در نظر گرفته می‌شود. روش دوم پیشنهادی، اولين روش همانندجوي احتمالاني ارائه شده برای زبان فارسی است که در آن با استفاده از اطلاعات آماري به دست آمده از پيکره‌اي عظيم از متون فارسی، همانندی دو واحد متن بررسی می‌شود. همانند روش معنائي پیشنهادی، روش احتمالاني پیشنهادی نيز در بررسی همانندی دو واحد متن، همانندی واحدهای مجاور را در نظر می‌گيرد.

در ادامه اين مقاله، در بخش دوم پيشينهه مسئله بررسی می‌شود. در بخش سوم، به روش‌های همانندجوي پیشنهادی اشاره شده و در بخش چهارم، به ارزیابی روش‌های ارائه شده خواهیم پرداخت. در نهايیت، نتيجه‌گيري در بخش پنجم بيان می‌شود.

۲. پيشينهه پژوهش

در اين بخش، ابتدا به بررسی روش‌های ارائه شده برای همانندجوي در سایر زبان‌ها پرداخته و سپس، روش‌های ارائه شده برای همانندجوي در زبان فارسی را بررسی خواهیم کرد.

۱-۱. همانندجويي در ساير زبانها

روش‌های همانندجويی تک‌زبانی را می‌توان با توجه به ابزارهای مورد استفاده در آن‌ها به دسته‌های (۱) همانندجويی مبتنی بر کاراکتر، (۲) همانندجويی مبتنی بر بردار، (۳) همانندجويی مبتنی بر گرامر، (۴) همانندجويی معنایی، (۵) همانندجويی احتمالاتی، (۶) همانندجويی ساختاری، و (۷) همانندجويی مبتنی بر شبک نگارش تقسیم‌بندی کرد (Alzahrani, Salim and Abraham 2012). روشهای همانندجويی مبتنی بر شبک نگارش فقط یکتایی نویسنده در یک متن را بررسی کرده و از دقت بالا در تشخیص قسمت‌های همانند برخوردار نیستند. روشهای همانندجويی ساختاری فقط در تشخیص سرتق ایده کاربرد دارند. روشهای مبتنی بر کاراکتر، روشهای مبتنی بر بردار و روشهای گرامری در تشخیص همانندی‌های حاصل از بازنویسی متون از کیفیت مناسبی برخوردار نیستند. از میان دسته‌های بیان شده تنها دسته‌های شماره ۴ و ۵ یعنی روشهای معنایی و احتمالاتی به نحوی مطلوب قادر به تشخیص همانندی‌های حاصل از بازنویسی متون هستند. در ادامه این بخش، به بررسی روشهای همانندجويی معنایی و احتمالاتی ارائه شده برای سایر زبان‌ها می‌پردازیم. لازم به ذکر است که در کلیه روشهایی که در ادامه بررسی می‌کنیم، ابتدا پیش‌پردازش‌های خاص زبانی اعمال می‌شود.

در روشن ارائه شده توسط Li et al. (2006)، که یک روشن همانندجويی معنایی برای همانندجويی در زبان انگلیسی است، برای بررسی همانندی، ابتدا لغات وزن‌دهی شده و سپس با استفاده از یک لغت‌نامه، همانندی مایین لغات به همانندی بین جملات توسعه داده می‌شود. علاوه بر این، روشن مورد نظر برای دستیابی به نتایج بهتر همانندی ترتیبی حضور لغات رانیز در نظر می‌گیرد. در پژوهش Adam (2014)، به طور همزمان از ابزار گرامری (تشخیص دهنده اقسام کلمه) و لغت‌نامه برای همانندجويی استفاده شده است. در این Ng (2005) یک روشن همانندجويی احتمالاتی برای زبان انگلیسی ارائه کرده‌اند. در این روش، با استفاده از پیکره‌ای بزرگ و با توجه به هر خدادای هر دو واژه در متون، مقداری احتمالاتی بین ۰ و ۱ به عنوان همانندی آن‌ها اختصاص داده شده و سپس، میانگین ییشینه همانندی لغات جمله اول با لغات جمله دوم به عنوان همانندی دو جمله محاسبه شده است. در این روشن، برای محاسبه همانندی هر دو واژه تنها حضور آن‌ها در متون مختلف در نظر گرفته می‌شود و تعداد تکرار آن‌ها در متون در نظر گرفته نمی‌شود. در روشن Koberstein (and Ng 2006)، با در نظر گرفتن دفعات تکرار واژگان در متون، روشن ارائه شده برای تعیین

میزان همانندی هر دو واژه در (Yerra and Ng (2005)، در راستای دستیابی به نتایج بهتر اصلاح شده است. با وجود این، همان‌طور که نویسنده‌گان بیان کرده‌اند، بهبود به دست آمده در نتایج این روش در مقایسه با افزایش قدرت محاسباتی مورد نیاز آن قابل توجه نیست. در نتایج این روش در مقایسه با زبان عربی ارائه شده در (Alzahrani and Salim (2009) Alzahrani and Salim (2009)، روشهای مشابه با روش ارائه شده در (Yerra and Ng (2005) برای معنایی در کنار الگوریتم‌های تطبیق رشته برای همانندجويی استفاده شده است. Gipp and Meuschke (2011)، از روشهای همانندجويی معنایی در (Salim and Palade (2015)، با تلفیق روشهای همانندجويی معنایی و احتمالاتی ارائه شده در (Li et al. (2006) و (Yerra and Ng (2005) و همچنین استفاده از تشخیص دهنده‌های اقسام کلمه نتایج بهتری برای همانندجويی در زبان انگلیسی به دست آورده‌اند.

۲-۲. همانندجويي در زبان فارسي

اغلب روشهای همانندجويی ارائه شده تا به امروز برای زبان فارسي تنها جهت تشخيص کپی دقیق بوده‌اند که از مهم‌ترین آن‌ها می‌توان به Mahmoodi and Varnamkhasti (2014); Minaei and Niknam (2014); Mahdavi, Siadati and Yaghmaee (2014) Rafieian (2016); اشاره کرد. در روشی که (Gharavi et al. (2016) ارائه کرده‌اند، از روشهای یادگیری عمیق برای همانندجويی استفاده شده است. در این روش با استفاده از روشهای شبکه عصبی عمیق، هر لغت با یک بردار نمایش داده شده که این بردار حاوی اطلاعات معنایی و گرامری در مورد آن لغت است که در نهایت، از این بردارها برای بررسی همانندی دو متن استفاده شده است. لازم به ذکر است که این روش برای مسابقات همانندجويی در زبان فارسي طراحی شده و جزئيات چندان دقیقی درباره آن بیان نشده است. Mashhadirajab and Shamsfard (2016) یک روش همانندجويی جدید ارائه کرده‌اند که می‌توان آن را به عنوان یک روش ترکیبی از روشهای برداری و معنایی در نظر گرفت. این روش جهت ارائه به اولین دوره مسابقات همانندجويی طراحی شده است. با توجه به این موضوع، از آنجا که در مجموعه متون مسابقه در هر متن تنها یک نوع سرقت علمی از $3^{\text{نوع}} \text{سرقت}$ علمی (کپی دقیق، شبیه‌سازی کامپیوتری و شبیه‌سازی انسانی) انجام شده، در این روش، ابتدا با استفاده از روشهای دسته‌بندی، نوع سرقت علمی مشخص شده و سپس، از شبکه واژگانی زبان فارسي برای بررسی همانندی دو متن استفاده می‌شود. با توجه به این که در دنیای واقعی سرقت علمی به تفکیک در نظر گرفته شده در Mashhadirajab and Shamsfard

(2016) انجام نمی‌شود، به نظر می‌رسد پیاده‌سازی این روش در دنیای واقعی به نتایج ضعیف‌تری منجر گردد.

با توجه به ادبیات موضوع و پژوهش‌های پیشین، روش‌های متعددی برای همانندجوبی متون بازنویسی شده در زبان‌های دیگر ارائه شده است، لیکن بسیاری از آن‌ها به سادگی قابل پیاده‌سازی برای زبان فارسی نبوده و به قواعد زبانی وابسته هستند. از طرفی، از بین روش‌های ارائه شده برای زبان فارسی، روشی که (Gharavi et al. 2016) ارائه کردۀاند، نتایج نسبتاً مشابهی با سایر روش‌ها دارد و بر اساس نتایج آزمایش‌های انجام‌شده در پژوهش ایشان، برخی شاخص‌ها مانند دقت و سرعت از سایر روش‌ها بهتر است. در روش آن‌ها بُرداری برای هر جمله بر اساس میانگین کلمات آن بیان می‌شود و کلمات دو جمله به صورت جداگانه با هم مقایسه نمی‌شوند. بنابراین، ممکن است با میانگین‌گیری، اثر کلمات مشابه از بین برود. در پژوهش حاضر، روشی پیشنهاد شده است که می‌تواند در سطح کلمه، همانندی بین جملات را بررسی کند.

۳. روش پژوهش

در این پژوهش با مطالعه متابع علمی معتبر دو روش پیشنهاد می‌شود که از طریق آن‌ها بتوان همانندی دو متن بازنویسی شده را محاسبه نمود. برای جمع‌آوری اطلاعات پژوهش، از روش کتابخانه‌ای استفاده شده و نتایج به کار گیری دو روش پیشنهادی روی مجموعه‌ای از داده‌ها ارزیابی و تحلیل شده است. برای تحلیل نتایج و مقایسه آن‌ها از شاخص‌های مختلفی نظیر دقت، فراخوانی، دانه‌دانه بودن و *plagdet* استفاده شده است.

پیاده‌سازی روش‌های ارائه شده با استفاده از زبان برنامه‌نویسی #0 انجام شده و در ادامه، از کامپیوتری با پردازندهٔ مرکزی "3.7 GHz Intel i3"، حافظهٔ داخلی "4 GB" و سیستم عامل ۶۴ بیتی ویندوز ۷ آزمایشاتی جهت بررسی کیفیت الگوریتم‌های پیشنهادی استفاده شده است. آزمایش‌های صورت گرفته بر روی مجموعه داده آزمایش منتشر شده با این هدف و برای کنفرانس تشخیص سرقت علمی در زبان فارسی انجام شده است. در ادامه، برخی ملاحظات صورت گرفته در پیاده‌سازی الگوریتم‌های پیشنهادی بیان می‌شود:

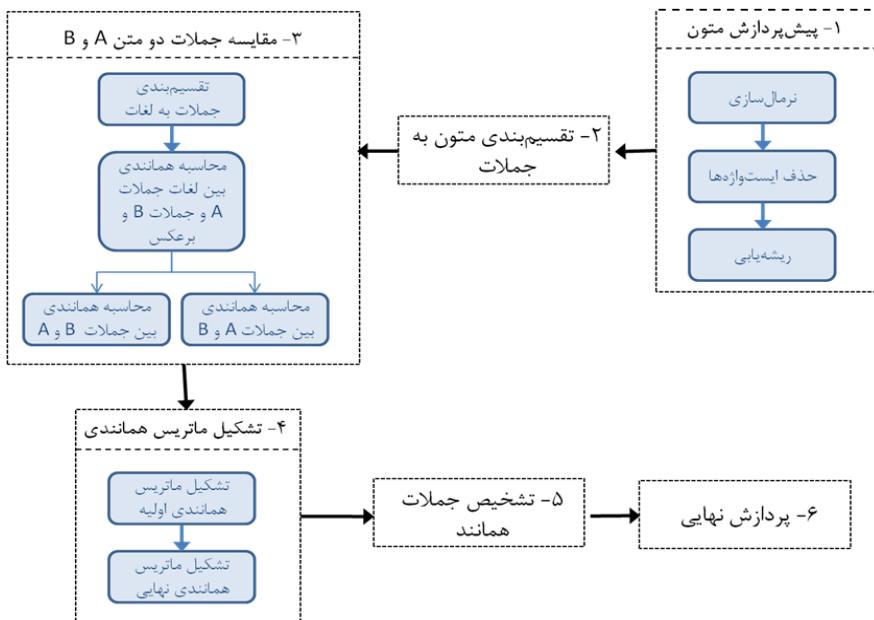
- ◊ در پیاده‌سازی‌های انجام‌شده، برای ریشه‌یابی لغوی از «ابزار پارسرا زبان فارسی» (استیری و همکاران ۱۳۹۱) استفاده شده است.
- ◊ لیست ایست‌واژه‌های زبان فارسی مورد استفاده در پیاده‌سازی‌های صورت گرفته با

- توجه به پژوهش (Taghva, Beckley and Sadeh 2003) بددست آمده است.
- ◇ لغت‌نامه مورد استفاده در الگوريتم معنائي پيشنهادي جهت بررسی نزديکي معنائي دو واژه «فرهنگ جامع واژگان متراff و متضاد زبان فارسي» تأليف (Khodaparasti 1997) است.
- ◇ برای محاسبه فراوانی واژگان و فراوانی همرخدادی واژگان بهمنظور استفاده در الگوريتم همانندجوي احتمالاتي پيشنهادي، با توجه به قدرت محاسباتي در دسترس، از قسمتي از پيکره «همشهری» (AleAhmad et al. 2009) به عنوان پيکره مرجع استفاده شده (حدود ۲۰ درصد از داده‌های اين پيکره که به صورت تصادفي انتخاب شده‌اند) و جدول همرخدادی لغات در هر دنباله ۳۱ کلمه‌ای پياپي از متون اين مجموعه محاسبه شده است.

لازم به ذكر است که متأسفانه با توجه به عدم دسترسی به پياده‌سازی سايروش‌های ارائه‌شده برای همانندجوي در زبان فارسي، عدم دسترسی به مجموعه داده مورد استفاده برای آزمایش اين روش‌ها و همچنین، نبود نتایج ارزیابی اين روش‌ها روی مجموعه داده مورد بررسی در اين مقاله، امكان مقایسه روش‌های پيشنهادي با اين روش‌ها ممکن نیست.

۱-۳. روش‌های پيشنهادي برای همانندجوي

در اين بخش، دو روش همانندجويی جدید برای زبان فارسي ارائه می‌شود. روش اول پيشنهادي يك روش معنائي است که از ابزار لغت‌نامه برای بررسی همانندی واحد‌های مختلف متن استفاده می‌کند. روش دوم پيشنهادي يك روش احتمالاتي است که در آن همانندی هر دو واحد از متن با توجه به اطلاعات آماری بددست آمده از پيکره‌اي عظيم از متون فارسي محاسبه می‌شود. فرایند اصلی هر دو روش در شکل ۱، نمايش داده شده است. در ادامه، هر يك از بخش‌های اين فرایند برای هر دو روش پيشنهادي به تفکيك تشریح می‌گردد.



شکل ۱. فرایند کلی در هر دو روش همانندجويي پیشنهادی

۳-۱-۱. روش همانندجويي معنائي پیشنهادی

در روش همانندجويي معنائي پیشنهادی، ابتدا پيش پردازش های ريشه يابی لغوی، نرمال سازی متن و حذف ایستوازه ها بر روی متن مشکوک و متن منبع احتمالی انجام می شود. در ادامه، پس از تقسیم متنون ورودی به واحد های مناسب، همانندی هر دو واحد با استفاده از ابزار لغت نامه تعیین می شود. در مقایسه با سایر روش های معنائي ارائه شده برای زبان فارسي، در اين روش از معيار های جديدي تری برای بررسی همانندی استفاده می شود. علاوه بر اين، در اين روش، همانندی دو واحد مختلف متن به صورت مجزا بررسی نمي شود، بلکه در بررسی همانندی اين دو واحد، همانندی واحد های نزديک به آن ها در متن مشکوک و متن منبع احتمالی نيز در نظر گرفته می شود.

فرض کنيد A متن مشکوک و B متن منبع احتمالی باشد. در روش معنائي پیشنهادی برای مقاييس A و B به صورت زير عمل می شود:

پيش پردازش متنون: پيش پردازش های زير بر روی متن مشکوک A و متن منبع احتمالی B انجام می شود:

نرمال‌سازی: در نرمال‌سازی، تنها حروف فارسی و علامت نقطه‌گذاری نگهداری شده و بقیه کاراکترها حذف می‌شوند.

حذف ایست‌واژه‌ها: با توجه به فراوانی استفاده از ایست‌واژه‌ها، این پیش‌پردازش از تأثیر منفی ایست‌واژه‌ها در همانندجویی جلوگیری می‌کند.

ریشه‌یابی: ریشه‌یابی لغوی بر روی هر دو متن اعمال می‌شود تا لغات متون به ریشه‌های آن‌ها در زبان فارسی تبدیل شوند.

تقسیم‌بندی متون به جملات: متون A و B به جملات تقسیم‌بندی می‌شوند. در این صورت $AS_{|A|}, AS_2, \dots, AS_{|B|}$ جملات موجود در متن A و $BS_{|B|}, BS_2, \dots, BS_1$ جملات موجود در متن B به ترتیب حضور در این متون و $|A|$ و $|B|$ تعداد جملات متون مورد نظر هستند.

مقایسه جملات دو متن: هر جمله AS_i از متن A با هر جمله BS_j از متن B به صورت زیر مقایسه می‌شود:

تقسیم‌بندی جملات به لغات: جملات AS_i و BS_j به مجموعه لغات تقسیم‌بندی می‌شوند.
فرض کنیم $\{AS_i^1, AS_i^2, \dots, AS_i^n\}$ مجموعه لغات جمله AS_i و $\{BS_j^1, BS_j^2, \dots, BS_j^m\}$ مجموعه لغات جمله BS_j باشند.

محاسبه همانندی بین لغات جمله‌ای از متن A با جمله‌ای از متن B و بر عکس: همانندی هر لغت AS_i^k از جمله AS_i و هر لغت BS_j^l از جمله BS_j که با $Sim_{AS_i^k \leftrightarrow BS_j^l}$ نمایش داده می‌شود، به صورت زیر محاسبه می‌شود:

◇ در صورتی که دو واژه یکسان باشند، $Sim_{AS_i^k \leftrightarrow BS_j^l}$ برابر با ۱ در نظر گرفته می‌شود.

◇ در غیر این صورت، مقدار $Sim_{AS_i^k \leftrightarrow BS_j^l}$ با استفاده از لغتنامه مورد استفاده در الگوریتم محاسبه می‌شود. در آزمایشات صورت گرفته از لغتنامه‌ای عمومی، که تنها شامل لغات مترادف و متضاد است، استفاده شده و در نتیجه، در صورت وجود یکی از این کلمات مایبن مترادف‌ها و متضادهای دیگر مقدار $Sim_{AS_i^k \leftrightarrow BS_j^l}$ برابر با $\sqrt{\frac{1}{2}}$ قرار خواهد گرفت (مقدار $\sqrt{\frac{1}{2}}$ توسط آزمایش‌ها محاسبه می‌شود).

در روش‌های معنایی، برای محاسبه همانندی یک لغت به یک جمله، همانندی نزدیک ترین لغت از جمله به لغت مورد نظر در نظر گرفته می‌شود. بنابراین، در روش پیشنهادی،

همانندی هر لغت AS_i^k از جمله AS_i با جمله BS_j که با $Sim_{AS_i^k \leftrightarrow BS_j}$ نمایش داده می‌شود، برابر با بیشینه $Sim_{AS_i^k \leftrightarrow BS_j^l}$ برای $l = 1, \dots, m$ در نظر گرفته می‌شود. به همین ترتیب، همانندی هر واژه BS_j^l از جمله BS_j با جمله AS_i محاسبه شده و $Sim_{BS_j^l \leftrightarrow AS_i}$ نمایش داده می‌شود.

محاسبه همانندی هر جمله از متن A با هر جمله از متن B بر اساس همانندی لغات آن‌ها: میزان همانندی جمله AS_i نسبت به جمله BS_j با استفاده از فرمول زیر محاسبه می‌شود:

$$Sim_{AS_i \rightarrow BS_j} = \frac{\sum_{k=1}^n Sim_{AS_i^k \rightarrow BS_j}}{n} \quad (1)$$

محاسبه همانندی هر جمله از متن B با هر جمله از متن A بر اساس همانندی لغات آن‌ها: میزان همانندی جمله BS_j نسبت به جمله AS_i با استفاده از فرمول زیر محاسبه می‌شود:

$$Sim_{BS_j \rightarrow AS_i} = \frac{\sum_{l=1}^m Sim_{BS_j^l \rightarrow AS_i}}{m} \quad (2)$$

تشکیل ماتریس همانندی: ابتدا ماتریس همانندی اولیه تشکیل می‌شود. سپس، با در نظر گرفتن اثر جملات همسایه، این ماتریس بهبود می‌یابد و ماتریس همانندی نهایی تشکیل می‌شود.

تشکیل ماتریس‌های همانندی اولیه: با استفاده از مقادیر محاسبه شده به عنوان میزان همانندی جملات مختلف دو متن، ماتریس‌های اولیه $Sim_{A \rightarrow B} = [a_{ij}]_{i=1 \dots |A|}^{j=1 \dots |B|}$ و $Sim_{B \rightarrow A} = [b_{ij}]_{i=1 \dots |A|}^{j=1 \dots |B|}$ ساخته می‌شوند که

$$a_{ij} = \begin{cases} 2 & \text{if } Sim_{AS_i \rightarrow BS_j} > \alpha_1 \& \left(Sim_{AS_i \rightarrow BS_j} \right)^{\frac{1}{\log_{\delta}^{n/\delta}}} > \alpha'_1 \\ 1 & \text{if } \beta_1 < Sim_{AS_i \rightarrow BS_j} < \alpha_1 \& \beta'_1 < \left(Sim_{AS_i \rightarrow BS_j} \right)^{\frac{1}{\log_{\delta}^{n/\delta}}} < \alpha'_1 \\ 0 & \text{Otherwise} \end{cases} \quad (3)$$

$$b_{ij} = \begin{cases} 2 & \text{if } Sim_{BS_j \rightarrow AS_i} > \alpha_2 \text{ \& } \left(Sim_{BS_j \rightarrow AS_i} \right)^{\frac{1}{\log_{\delta}^{n/\delta}}} > \alpha'_2 \\ 1 & \text{if } \beta_2 < Sim_{BS_j \rightarrow AS_i} < \alpha_2 \text{ \& } \beta'_2 < \left(Sim_{BS_j \rightarrow AS_i} \right)^{\frac{1}{\log_{\delta}^{m/\delta}}} < \alpha'_2 \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

که $\alpha_1, \alpha'_1, \alpha_2, \alpha'_2, \beta_1, \beta'_1, \beta_2, \beta'_2$ مقادیری آستانه‌ای و δ ثابت بوده و با انجام آزمایش محاسبه می‌شوند. همان‌طور که از روابط (۱) و (۲) مشخص است، طول جملات یعنی n و m در محاسبه مقادیر از طریق این فرمول‌ها تأثیر زیادی دارند. این اثرگذاری زمانی باعث مشکل خواهد شد که جمله‌ها در بازنویسی، ترکیب یا تجزیه شوند. برای حل این مشکل باید به طریقی این اثرگذاری را در نظر گرفت. به عنوان یک راهکار، می‌توان از مقادیر آستانه‌ای متفاوت برای جملات با طول متفاوت استفاده کرد. به عنوان یک روش کلی‌تر، در روش ارائه شده در این مقاله، از یک رابطه ابتکاری استفاده شده که طی آن، با به‌توان $\frac{1}{\log_{\delta}^{n/\delta}}$ رساندن مقادیر حاصل از فرمول‌های (۱) و (۲) این موضوع در نظر گرفته شده است. توجه کنید که از آنجا که مقادیر همانندی محاسبه شده از طریق فرمول‌های (۱) و (۲) بین صفر و یک هستند، با به‌توان $\frac{1}{\log_{\delta}^{n/\delta}}$ رساندن، مقدار ثانویه محاسبه شده برای جملات طولانی افزایش خواهد یافت. برای مثال، با در نظر گرفتن $n=2$ ، مقدار $\frac{1}{\log_{\delta}^{n/\delta}}$ برای $n=4$ برابر با ۱، برای $n=8$ این مقدار برابر با $\frac{1}{2}$ ، و برای $n=16$ این مقدار برابر با $\frac{1}{4}$ خواهد بود. در نتیجه، برای n ‌های بزرگ‌تر، استفاده از این رویکرد منجر به افزایش مقدار محاسبه شده خواهد شد و بدین طریق، ترکیب و تجزیه جملات تا حدودی در نظر گرفته خواهد شد.

تشکیل ماتریس همانندی نهایی: با استفاده از مؤلفه‌های دو ماتریس به دست آمده در مرحله قبل، ماتریس نهایی همانندی $[h_{ij}] = H$ به صورت زیر ایجاد می‌شود:

$$h_{ij} = \begin{cases} 1 & \text{if } (a_{ij} \geq 1 \& b_{ij} \geq 1) \text{ \& } (\exists k, l \in \{-1, 0, 1\} \text{ s.t.: } (a_{i+k, j+l} = 2 \& b_{i+k, j+l} = 2)) \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

تشخیص جملات همانند: در نهایت، جمله AS_i از متن A و جمله BS_j از متن B همانند

شناخته می‌شوند اگر $h_i = 1$

پردازش نهایی: پس از مشخص شدن جملات مشابه دو متن، فرایند زیر بر روی متن مشکوک و متن منبع احتمالی انجام می‌شود تا قسمت‌های همانند تشخیص داده شده مجزا به یکدیگر متصل شده و قسمت‌های با طول کم حذف شوند:

در صورتی که دو جمله نزدیک به هم در متن مشکوک (در متن منبع احتمالی) همانند تشخیص داده شود و فاصله آن‌ها در متن کمتر از مقداری آستانه‌ای باشد، قسمت همانند تشخیص داده شده، از ابتدای جمله اول تا انتهای جمله دوم در نظر گرفته می‌شود. در پیاده‌سازی‌های صورت گرفته، از نصف مجموع طول دو جمله همانند تشخیص داده شده به عنوان این مقدار آستانه‌ای استفاده شده است.

در صورتی که قسمتی از متن همانند تشخیص داده شده و پس از انجام مرحله قبل طول آن همچنان کمتر از مقدار آستانه‌ای باشد، این قسمت از مجموعه متون همانند تشخیص داده شده حذف می‌گردد. در پیاده‌سازی‌های صورت گرفته از ۴ کلمه به عنوان این مقدار آستانه‌ای استفاده شده است.

توجه: در انجام سرقت علمی، به‌طور معمول، بخش‌هایی شامل چندین جمله پیاپی از یک متن منبع در متنی جدید بازنویسی می‌شود. با توجه به این مهم، در صورت تشخیص همانندی مابین یک جمله از یک متن مشکوک و یک جمله از یک متن منبع، در بررسی همانندی جملات مجاور آن‌ها باید حساسیت بیشتری قائل شد. همان‌طور که نتایج پیاده‌سازی روش‌های پیشنهادی (در بخش ۴) نشان می‌دهد، این اقدام (که از طریق مرحله تشکیل ماتریس همانندی نهایی در الگوریتم فوق و الگوریتم همانندجویی احتمالاتی ارائه شده در بخش بعد پیاده‌سازی شده) منجر به دستیابی به نتایجی بهتر شده است.

۲-۱-۳. روش همانندجویی احتمالاتی پیشنهادی

در این قسمت یک روش احتمالاتی برای همانندجویی در متون فارسی بازنویسی شده ارائه می‌کنیم. همانند الگوریتم ارائه شده در بخش قبل، در این روش نیز ابتدا پیش‌پردازش‌های ریشه‌یابی لغوی، نرمال‌سازی متن و حذف ایست‌واژه‌ها بر روی هر دو متن ورودی انجام می‌شود. در ادامه، پس از تقسیم متون ورودی به واحدهای مناسب، همانندی هر دو واحد با استفاده از فراوانی‌های لغات و فراوانی‌های هم‌رخدادی آن‌ها

با توجه به پیکرهای عظیم از متون فارسی محاسبه می‌شود. همانند روش قبل، در روش احتمالاتی پیشنهادی نیز همانندی دو واحد مختلف متن به صورت مجزا بررسی نمی‌شود، بلکه در بررسی همانندی این دو واحد، همانندی واحدهای نزدیک به آن‌ها در متن مشکوک و B متن منبع احتمالی نیز در نظر گرفته می‌شود. فرض کنید A متن مشکوک و B متن منبع احتمالی باشد. در روش احتمالاتی پیشنهادی برای مقایسه یک متن مشکوک با یک متن منبع احتمالی به صورت زیر عمل می‌شود:

پیش‌پردازش متون: پیش‌پردازش‌های زیر بر روی متن مشکوک A و متن منبع احتمالی B انجام می‌شود:

نرمال‌سازی: در نرمال‌سازی تنها حروف فارسی و علائم نقطه‌گذاری نگهداری شده و بقیه کاراکترها حذف می‌شوند.

حذف ایست‌واژه‌ها: با توجه به فراوانی استفاده از ایست‌واژه‌ها، این پیش‌پردازش از تأثیر منفی ایست‌واژه‌ها در همانندجویی جلوگیری می‌کند.

ریشه‌یابی: ریشه‌یابی لغوی بر روی هر دو متن اعمال می‌شود تا لغات متون به ریشه‌های آن‌ها در زبان فارسی تبدیل شوند.

تقسیم‌بندی متون به جملات: متون A و B به جملات تقسیم‌بندی می‌شوند. در این صورت $AS_{|A|}, AS_2, AS_1, \dots, AS_{|B|}$ جملات موجود در متن A و $BS_{|B|}, BS_2, BS_1, \dots, BS_{|A|}$ جملات موجود در متن B به ترتیب حضور در این متون و $|A|$ و $|B|$ تعداد جملات متون مورد نظر هستند.

مقایسه جملات دو متن: هر جمله AS_i از متن A با هر جمله BS_j از متن B به صورت زیر مقایسه می‌شود:

تقسیم‌بندی جملات به لغات: جملات AS_i و BS_j به مجموعه لغات تقسیم‌بندی می‌شود. فرض کنیم $\{AS_i^1, AS_i^2, \dots, AS_i^n\}$ مجموعه لغات جمله AS_i و $\{BS_j^1, BS_j^2, \dots, BS_j^m\}$ مجموعه لغات جمله BS_j باشند.

محاسبه همانندی بین لغات جمله‌ای از متن A با جمله‌ای از متن B و برعکس: همانندی هر لغت AS_i^k از جمله AS_i و هر لغت BS_j^l از جمله BS_j که با $Sim_{AS_i^k \leftrightarrow BS_j^l}$ نمایش داده می‌شود، به صورت زیر محاسبه می‌شود:

- ◊ در صورتی که دو واژه یکسان باشند، $Sim_{AS_i^k \leftrightarrow BS_j^l}$ برابر با ۱ قرار می‌گیرد.
- ◊ در غیر این صورت، $Sim_{AS_i^k \leftrightarrow BS_j^l}$ به صورت زیر محاسبه می‌شود:

$$Sim_{AS_i^k \leftrightarrow BS_j^l} = \frac{n_{AS_i^k BS_j^l}}{n_{AS_i^k} + n_{BS_j^l} - n_{AS_i^k BS_j^l}} \quad (6)$$

که $n_{AS_i^k}$ فراوانی لغت AS_i^k ، $n_{BS_j^l}$ فراوانی لغت BS_j^l و $n_{AS_i^k BS_j^l}$ فراوانی هم خدادی این دو لغت است که این فراوانی‌ها با توجه به پیکرهای از متون فارسی محاسبه شده‌اند.

همانندی هر لغت AS_i^k از جمله AS_i با جمله BS_j که با $Sim_{AS_i^k \leftrightarrow BS_j^l}$ نمایش داده می‌شود، برابر با یشینه $(l=1, \dots, m)$ قرار داده می‌شود.

به همین ترتیب، همانندی هر واژه BS_j^l از جمله BS_j با جمله AS_i محاسبه شده و با $Sim_{BS_j^l \leftrightarrow AS_i}$ نمایش داده می‌شود. محاسبه همانندی هر جمله از متن A با هر جمله از متن B بر اساس همانندی لغات آن‌ها؛ میزان همانندی جمله AS_i به جمله BS_j و میزان همانندی جمله BS_j به AS_i به ترتیب با استفاده از فرمول‌های زیر محاسبه می‌شود:

$$Sim_{AS_i \rightarrow BS_j} = \frac{\sum_{k=1}^n Sim_{AS_i^k \rightarrow BS_j}}{n} \quad (7)$$

$$Sim_{BS_j \rightarrow AS_i} = \frac{\sum_{l=1}^m Sim_{BS_j^l \rightarrow AS_i}}{m} \quad (8)$$

تشکیل ماتریس همانندی: ابتدا ماتریس همانندی اولیه تشکیل می‌شود. سپس، با درنظر گرفتن اثر جملات همسایه، این ماتریس بهبود می‌یابد و ماتریس همانندی نهایی تشکیل می‌شود.

تشکیل ماتریس‌های اولیه همانندی: با استفاده از مقادیر محاسبه شده به عنوان میزان همانندی جملات مختلف دو متن، ماتریس‌های اولیه $Sim_{A \rightarrow B} = [a_{ij}]_{i=1 \dots |A|}^{j=1 \dots |B|}$ و $Sim_{B \rightarrow A} = [b_{ij}]_{i=1 \dots |A|}^{j=1 \dots |B|}$ ساخته می‌شوند که

$$a_{ij} = \begin{cases} 2 & \text{if } Sim_{AS_i \rightarrow BS_j} > \alpha_1 \\ 1 & \text{if } \beta_1 < Sim_{AS_i \rightarrow BS_j} < \alpha_1 \\ 0 & \text{if } Sim_{AS_i \rightarrow BS_j} < \beta_1 \end{cases} \quad (9)$$

$$b_{ij} = \begin{cases} 2 & \text{if } Sim_{BS_j \rightarrow AS_i} > \alpha_2 \\ 1 & \text{if } \beta_2 < Sim_{BS_j \rightarrow AS_i} < \alpha_2 \\ 0 & \text{if } Sim_{BS_j \rightarrow AS_i} < \beta_2 \end{cases} \quad (10)$$

که α_1 ، α_2 ، β_1 و β_2 مقادیری آستانه‌ای بوده و با انجام آزمایشات محاسبه می‌شوند.

تشکیل ماتریس همانندی نهایی: با استفاده از مؤلفه‌های دو ماتریس به دست آمده در مرحله قبل، ماتریس نهایی همانندی $H = [h_{ij}]$ به صورت زیر ایجاد می‌شود:

$$h_{ij} = \begin{cases} 1 & \text{if } (a_{ij} \geq 1 \& b_{ij} \geq 1) \& (\exists k, l \in \{-1, 0, 1\} \text{ s.t.: } (a_{i+k, j+l} = 2 \& b_{i+k, j+l} = 2)) \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

تشخیص جملات همانند: در نهایت، جمله AS_i از متن A و جمله BS_j از متن B همانند شناخته می‌شوند اگر $h_{ij} = 1$.

پردازش نهایی: پس از مشخص شدن جملات مشابه دو متن، فرایند زیر بر روی متن مشکوک و متن منبع احتمالی انجام شده و قسمت‌های همانند تشخیص داده شده مجزا به یکدیگر متصل شده و قسمت‌های با طول کم حذف می‌شوند:

◇ در صورتی که دو جمله نزدیک به هم در متن مشکوک (در متن منبع احتمالی) همانند تشخیص داده شود و فاصله آن‌ها در متن کمتر از مقدار آستانه‌ای باشد، قسمت همانند تشخیص داده شده برابر با ابتدای جمله اول تا انتهای جمله دوم در نظر گرفته می‌شود. در پیاده‌سازی‌های صورت گرفته، از نصف طول دو جمله همانند تشخیص داده شده به عنوان این مقدار آستانه‌ای استفاده شده است.

◇ در صورتی که قسمتی از متن همانند تشخیص داده شده و پس از انجام مرحله قبل طول آن همچنان کمتر از مقدار آستانه‌ای باشد، این قسمت از مجموعه متون همانند تشخیص داده شده حذف می‌گردد. در پیاده‌سازی‌های صورت گرفته از ۴ کلمه به عنوان این مقدار آستانه‌ای استفاده شده است.

۲-۳. ارزیابی روش‌های همانندجویی پیشنهادی

در این بخش، ابتدا معیارهای ارزیابی یک روش همانندجو را بررسی کرده و در ادامه، پس از بیان جزئیات آزمایشات صورت گرفته بر روی روش‌های پیشنهادی، نتایج این آزمایشات را ارائه و روش‌های ارائه شده را با یکدیگر مقایسه می‌کنیم.

۳-۱. معیارهای ارزیابی یک روش همانندجویی

در این بخش، معیارهای بررسی کیفیت یک روش همانندجویی ارائه می‌شود تا در بخش‌های بعدی با استفاده از آن‌ها، کیفیت الگوریتم‌های پیشنهادی بررسی گردد. برای ارزیابی کیفیت یک الگوریتم همانندجو از سه پارامتر دقت^۱، فراخوانی^۲، دانه‌دانه‌بودن^۳ (Potthast et al. 2010) استفاده می‌شود. در ادامه، این پارامترها و نحوه محاسبه آن‌ها بیان خواهد شد.

فرض کنیم یک الگوریتم همانندجو را بروی یک متن مشکوک و یک متن منبع احتمالی اجرا کنیم. مجموعه R را به عنوان نمایشگر مجموعه موارد همانند تشخیص داده شده توسط الگوریتم در نظر می‌گیریم. همچنین، فرض می‌کنیم S نمایشگر مجموعه موارد همانند بین این دو متن باشد. در این صورت، پارامترهای دقت و فراخوان به صورت زیر تعریف می‌شوند:

$$prec(S, R) = \frac{1}{|R|} \sum_{r \in R} \frac{|\bigcup_{s \in S} r \cap r|}{|r|} \quad (12)$$

$$rec(S, R) = \frac{1}{|S|} \sum_{s \in S} \frac{|\bigcup_{r \in R} s \cap r|}{|s|} \quad (13)$$

که \bigcup_r کarakترهای همپوشان بین s و r است زمانی که آن‌ها در هر دو قسمت از متن مشکوک و متن منبع احتمالی حداقل یک کarakتر مشترک داشته باشند. در غیر این صورت، \bigcup_r s تهی است (Stamatatos 2011).

در همانندجویی، پارامترهای دقت و فراخوان تصویری کلی از تأثیرگذاری روش‌ها ارائه نمی‌کنند. در شرایطی که یک الگوریتم همانندجو قسمت‌های همپوشان از متن منبع احتمالی را به عنوان منبع برای یک مورد همانندی ارائه کند، یا در مواردی که قسمت‌های

متن منبع احتمالي به قسمت‌های کوچک‌تر تقسیم شده و بازگردانده شوند، پارامترهای مورد نظر تغییر خواهند کرد (افزایش خواهد یافت). در نتیجه، به معیار دیگری نیاز است که این موارد را در نظر بگیرد. برای تعریف معیار جدید فرض کنیم $S_R \subseteq S$ موارد تشخیص داده شده در R باشند و $R_s \subseteq R$ موارد تشخیص داده شده مربوط به S باشند. حال، معیار دانه‌دانه‌بودن به صورت زیر تعریف می‌شود:

$$Gran(S, R) = \frac{1}{|S_R|} \sum_{s \in S_R} |R_s| \quad (14)$$

کمترین مقدار برای این معیار ۱ است. هر قدر مقدار این پارامتر بیشتر باشد، قسمت‌های بیشتری از یک متن (احتمالاً همپوشان) در تناظر با یک مورد مشابه همانندی تشخیص داده شده است. پارامترهای دقت، فراخوانی و دانه‌دانه‌بودن را می‌توان با یکدیگر ترکیب و به صورت یک معیار کلی Plagdet که به صورت زیر تعریف می‌شود نمایش داد:

$$plag \det(S, R) = \frac{F_1}{\log_2(1 + Gran(S, R))} \quad (15)$$

که F_1 میانگین هارمونیک^۱ مقادیر پارامترهای دقت و فراخوان است. لازم به ذکر است که Plagdet پارامتر نهایی است که از آن در رتبه‌بندی الگوریتم‌های همانندجويي ارائه شده در مسابقات همانندجويي می‌شود.

۲-۲-۳. نتایج تجربی ارزیابی الگوریتم‌های همانندجويي پیشنهادی

در راستای بررسی نحوه کارکرد الگوریتم‌های پیشنهادی، این الگوریتم‌ها بر روی مجموعه داده‌هایی پیاده‌سازی شده‌اند و آزمایش‌هایی بر اساس این روش‌ها انجام شده است که در ادامه، جزئیات فعالیت‌های انجام شده در این قسمت و نتایج آن بیان خواهد شد.

۳-۲-۳. نحوه پیاده‌سازی

در این قسمت، ملاحظات صورت گرفته در پیاده‌سازی الگوریتم‌های پیشنهادی بیان می‌شود. همان‌طور که بیان شد، یکی از پیش‌پردازش‌های مورد نیاز در روش‌های پیشنهادی، انجام ریشه‌یابی لغوی است. در آزمایشات صورت گرفته، برای ریشه‌یابی

۱. میانگین هارمونیک (harmonic mean) چند پارامتر برابر است با تعداد آن‌ها تقسیم بر مجموع وارون آن‌ها.

لغوی از «ابزار پارسی زبان فارسی» (استیری و همکاران ۱۳۹۱) استفاده شده است. از دیگر پیش‌پردازهای مورد نیاز در الگوریتم‌های ارائه شده حذف ایست‌واژه‌های است که در الگوریتم‌های پیشنهادی از لیست ایست‌واژه‌های فراهم شده در (Taghva et al. 2003) استفاده شده است. ابزار دیگر مورد نیاز برای پیاده‌سازی الگوریتم معنایی پیشنهادی، وجود لغت‌نامه‌ای جهت بررسی نزدیکی معنایی دو واژه است. در پیاده‌سازی‌های صورت گرفته از «فرهنگ جامع واژگان متراff و متضاد زبان فارسی» تأليف (Khodaparasti 1997) استفاده شده است که در برگیرنده متراff و متضادهای واژگان است.

الگوریتم همانندجوي احتمالاتی پیشنهادی نيز نیازمند محاسبه فراوانی واژگان و فراوانی هم‌رخدادی واژگان با توجه به پیکره‌ای عظیم از متون فارسی است. برای محاسبه این مقادیر و با توجه به قدرت محاسباتی در دسترس، از قسمتی از پیکرۀ «همشهری» AleAhmad (2009) et al. ۲۰ درصد از داده‌های این پیکرۀ که به صورت تصادفی انتخاب شده‌اند) به عنوان پیکرۀ مرجع استفاده شده و جدول هم‌رخدادی لغات در هر دنباله ۳۱ کلمه‌ای پیاپی از متون این مجموعه محاسبه شده است.

پارامترهای مورد استفاده در آزمایشات صورت گرفته روی روش‌های پیشنهادی با استفاده از روش آزمون و خطا و با در نظر گرفتن مقادیر مختلف برای این پارامترها و انجام آزمایش روی قسمت کوچکی از مجموعه داده آزمایش محاسبه شده‌اند. با توجه به تعداد زیاد پارامترهای دخیل در محاسبات، برای ممکن شدن محاسبه مقادیر بهینه تقریبی برای پارامترهای مورد نظر در روش معنایی پیشنهادی، از مجموعه‌ای از مفروضات استفاده شده که عبارت‌اند از:

- ◇ $\alpha'_1 = \alpha'_2, \alpha_1 = \alpha_2, \beta'_1 = \beta'_2$ ، و تنها مضارب صحیح ۱/۰ در محاسبات این پارامترها در نظر گرفته شده است.
- ◇ مقدار پارامتر ۷ مضربی صحیح از ۱/۰ و کمتر از ۱ است.
- ◇ ۵ عددی صحیح و بزرگ‌تر از ۱ است.

با توجه به این رویکرد، مقادیر بهینه برای پارامترهای $\alpha'_1, \alpha'_2, \beta'_1, \beta'_2, \gamma, \delta$ در الگوریتم همانندجوي معنایی ارائه شده به ترتیب برابر با $۰/۴, ۰/۴, ۰/۴, ۰/۴, ۰/۳, ۰/۳, ۰/۹$ به دست آمده است.

به طریقی مشابه و با مفروضات زیر مقادیر بهینه تقریبی برای پارامترهای $\alpha_1, \alpha_2, \beta_1, \beta_2$ و ۶ در الگوریتم احتمالاتی پیشنهادی به ترتیب برابر با $۰/۰۲۵, ۰/۰۲۵, ۰/۰۳۵, ۰/۰۳۵, ۰/۰۳۵$ و $۰/۰۲۵$ است.

۱/ در نظر گرفته شده است:

◇ $\alpha_1 = \beta_1$ و $\alpha_2 = \beta_2$ و تنها مضارب صحیح $0/05$ در محاسبات این پارامترها در نظر گرفته شده است.

◇ مقدار پارامتر 7 مضربی صحیح از $0/01$ و کمتر از 1 است.

لازم به ذکر است که در آزمایشات صورت گرفته تنها به صورت ساده و برای ممکن شدن آزمایشات سعی شده مقادیر بهینه تقریبی برای پارامترهای مورد استفاده محاسبه شود. قطعاً با استفاده از روش‌های تنظیم پارامتر، می‌توان مقادیر دقیق بهینه برای پارامترهای مورد نظر را یافته و نتایج روش‌های پیشنهادی را بهبود داد. در اینجا اما، با توجه به عدم تمرکز این مقاله بر روی این مسئله، تنها به همین محاسبات بسته کرده و محاسبات دقیق‌تر در این زمینه را به آینده موکول می‌کنیم.

۴-۲-۳. ارزیابی

برای ارزیابی الگوریتم‌های ارائه شده از مجموعه داده ارائه شده به عنوان داده آزمایش در کنفرانس تشخیص سرقت علمی در زبان فارسی^۱ استفاده شده است. این مجموعه داده شامل مجموعه‌ای از متون منبع و مجموعه‌ای از متون مشکوک است که در آن متن منبع احتمالی هر متن مشکوک نیز مشخص شده است. علاوه بر این، قسمت‌های همانند موجود در هر زوج نیز مشخص شده که با استفاده از آن بررسی صحت نتایج الگوریتم‌های پیشنهادی ممکن خواهد بود.

موارد سرقت علمی موجود در این مجموعه به سه دسته تقسیم شده است:

۱. کپی دقیق شامل 198 مورد سرقت علمی؛

۲. بازنویسی شده توسط کامپیوتر شامل 1607 مورد سرقت علمی؛

۳. بازنویسی شده توسط کاربر انسانی شامل 147 مورد سرقت علمی.

برای ارزیابی الگوریتم‌های پیشنهادی، آن‌ها را بر روی زوج متون مشکوک و منبع احتمالی هر دسته اعمال کرده و نتایج آن‌ها را محاسبه می‌کنیم.

در دسته «بازنویسی شده توسط کاربر انسانی» که شامل متون همانند شبیه‌سازی شده توسط کاربر انسانی است، مقادیر پارامترهای مورد نیاز برای بررسی کیفیت الگوریتم معنایی طراحی شده به شرح زیر محاسبه شده است:

1. <http://www.ictrc.ac.ir/plagdet/>

پارامتر دقت برابر با 0.88 و پارامتر فراخوان برابر با 0.84 است. با توجه به این مهم و مقدار یک به عنوان پارامتر دانه‌دانه‌بودن با توجه به پیوستگی قسمت‌های همانند تشخیص داده شده، پارامتر نهایی همانند جویی پعنی plagdet برابر با 0.85 می‌شود.

این آزمایش با داده‌های یکسان بر روی الگوریتم احتمالاتی پیشنهادی نیز اجرا شده و مقادیر پارامترهای مورد نظر به شرح زیر محاسبه شده است. پارامتر دقت برابر با 0.86 و پارامتر فراخوان برابر با 0.86 . با توجه به این مهم و مقدار یک به عنوان پارامتر $plagdet$ برابر با 0.86 محاسبه شده است. دانه‌دانه‌بودن، پارامتر نهايی همانند جويي يعني $plagdet$ برابر با 0.86 ، محاسبه شده است. در دسته «بازنويسى شده توسط کامپيوتر» که شامل متون همانند شيه‌سازى شده توسط کامپيوتر است، مقادير پارامترهای مورد نياز برای بررسى كيفيت الگوریتم معنایي طراحی شده به شرح زیر محاسبه شده است: پارامتر دقت برابر با 0.90 و پارامتر فراخوان برابر با 0.91 . با توجه به این مهم و مقدار یک به عنوان پارامتر دانه‌دانه‌بودن با توجه به $plagdet$ پيوستگى قسمت‌های همانند تشخيص داده شده، پارامتر نهايی همانند جويي يعني $plagdet$ برابر با 0.90 می‌شود.

این آزمایش با داده‌های یکسان بر روی الگوریتم احتمالاتی پیشنهادی نیز اجرا شده و مقادیر پارامترهای مورد نظر به شرح زیر محاسبه شده است. پارامتر دقت برابر با 0.89 و پارامتر فراخوان برابر با 0.94 با توجه به این مهم و مقدار یک به عنوان پارامتر دانه‌دانه‌بودن با توجه به پیوستگی قسمت‌های همانند تشخیص داده شده، پارامتر نهایی همانند حجم سی رعنے، ابر 0.91 می‌شود.

در دسته «کپی دقیق» که شامل متون دقیقاً کپی شده است، مقادیر پارامترهای مورد نیاز برای بررسی کیفیت الگوریتم معنایی طراحی شده به شرح زیر محاسبه شده است: پارامتر دقت برابر با 0.92 و پارامتر فراخوان برابر با 0.98 . با توجه به این مهم و مقدار یک به عنوان پارامتر دانه‌دانه‌بودن با توجه به پیوستگی قسمت‌های همانند تشخیص داده شده، با امت نهایه همانند $plagdet$ ، $ا_1$ با 0.94 م شود.

این آزمایش با داده‌های یکسان بر روی الگوریتم احتمالاتی پیشنهادی نیز اجرا شده و مقادیر پارامترهای مورد نظر به شرح زیر محاسبه شده است. پارامتر دقت برابر با 0.98 و پارامتر فراخوان برابر با 0.99 با توجه به این مهم و مقدار یک به عنوان پارامتر دانه‌دانه‌بودن، پارامتر نهایی همانند جویی، یعنی $plagdet$ برابر با 0.93 می‌شود.

جدول ۱، به طور خلاصه، عملکرد دو الگوریتم پیشنهادی در این پژوهش را در

دسته‌های مختلف متون آزمایشي نشان می‌دهد. نتایج گزارش شده نشان دهنده اين است که در حالی که مقدار پaramتر دقت برای روش معنائي پيشنهادی به طور متوسط حدود ۲ درصد بالاتر است، مقدار پaramتر فراخوانی اين روش به طور متوسط حدود ۲ درصد کمتر از مقدار اين پaramتر برای روش احتمالاتي پيشنهادی است.

جدول ۱. مقایسه کیفیت الگوریتم‌های پيشنهادی

الگوریتم	کپی دقیق					
	معنایی	احتمالاتی	بازنويسي شده توسيع کاربر انساني	بازنويسي شده توسيع کامپيوتر	بازنويسي شده توسيع کاربر انساني	بازنويسي شده توسيع کامپيوتر
plagdet	نیز	آنها	آنها	آنها	آنها	آنها
معنایی	۰/۹۲	۰/۹۰	۰/۸۵	۰/۸۴	۰/۸۸	۰/۹۰
احتمالاتی	۰/۹۸	۰/۹۰	۰/۸۶	۰/۸۶	۰/۸۶	۰/۹۱

همان‌طور که بیان شد، یکی از نوآوری‌های روش‌های ارائه‌شده (حتی نسبت به روش‌های ارائه‌شده برای سایر زبان‌ها) این است که در بررسی همانندی دو جمله، همانندی جملات همسایه آن‌ها نیز در نظر گرفته می‌شود. برای بررسی میزان اثربخشی این اقدام در همانندجويي، اين مرحله را (مرحله تشکيل ماترييس همانندی نهايی از روش‌های معنائي و احتمالاتي که در آن ماترييس نهايی محاسبه می‌شود) از روش‌های ارائه‌شده حذف کرده و نتایج همانندجويي با روش‌های تغييرياته را بررسی می‌کنيم. اين نتایج در جدول ۲، گزارش شده است. همان‌طور که مشاهده می‌شود، حذف مراحل ذكر شده در الگوریتم‌های ارائه‌شده تأثير چندانی در پaramترهای دقت و فراخوانی همانندجويي در دسته کپی دقیق از موارد سرقت علمي نداشت، لیکن در دسته‌های بازنويسي شده، علی‌رغم ثابت ماندن تقریبی پaramتر دقت، پaramتر فراخوانی به طور محسوس (حدود ۵ درصد) کاهش یافته است. به عبارت دیگر، با در نظر گرفتن همانندی جملات همسایه دو جمله در بررسی همانندی آن‌ها، قدرت تشخیص همانندی متون بازنويسي شده بر اساس روش‌های پيشنهادی به میزان ۵ درصد افزایش یافته است.

جدول ۲. مقایسه کیفیت الگوریتم‌های پیشنهادی بدون در نظر گرفتن تأثیر همانندی دو جمله بر روی همانندی جملات همسایه آن‌ها

الگوریتم	کبی دقیق	بازنویسی شده توسط کامپیوتر						plagdet	۰/۸۳
		۰/۹۳	۰/۹۸	۰/۹۳	۰/۸۰	۰/۸۸	۰/۸۸		
معنایی	۱	۰/۸۷	۰/۹۱	۰/۹۵	۰/۹۸	۰/۹۳	۰/۸۳	۱	۰/۸۳
احتمالاتی	۱	۰/۹۰	۰/۸۹	۰/۹۴	۰/۹۸	۰/۹۱	۰/۸۳	۱	۰/۸۳

علاوه بر این، برای مقایسه زمان اجرای روش‌های همانندجويي پیشنهادی زمان پردازش لازم برای بررسی همانندی تمام موارد موجود در هر دسته از موارد سرقت علمی را محاسبه کرده و در جدول ۳، با یکدیگر مقایسه می‌کنیم. لازم به ذکر است که آزمایشات صورت گرفته بر روی کامپیوتری با پردازنده مرکزی "3.7 GHz Intel i3"، حافظه داخلی "4 GB" و سیستم عامل "Windows 7" انجام شده است. علاوه بر این، با توجه به یکسانی پیش‌پردازش‌های مورد نیاز در هر دو روش پیشنهادی، زمان‌های اجرای بیان شده بدون در نظر گرفتن زمان مورد نیاز برای پیش‌پردازش متون گزارش شده‌اند. نتایج محاسبات ارائه شده در آخرین ستون جدول ۳، بیانگر آن است که روش احتمالاتی پیشنهادی بسیار کاراتر بوده و میانگین زمان صرف شده برای بررسی هر مورد سرقت علمی با استفاده از آن تنها $\frac{3}{8}$ درصد زمان صرف شده توسط روش معنایی پیشنهادی است. بنابراین، روش همانندجويي احتمالاتی پیشنهادی از نظر سرعت پردازش بسیار سریع‌تر از روش همانندجويي معنایی عمل می‌کند.

جدول ۳. مقایسه زمان اجرای الگوریتم‌های پیشنهادی

الگوریتم	کبی دقیق	بازنویسی شده توسط کامپیوتر	بازنویسی شده توسط کاربر انسانی	میانگین زمان صرف شده برای بررسی هر مورد سرقت علمی	میانگین زمان صرف شده برای بررسی هر مورد سرقت علمی	
					۰/۶۳۶	۲/۶۳۶
معنایی	۵۳۰ ثانیه	۴۲۸۰ ثانیه	۲۳۷ ثانیه	۰/۶۳۶ ثانیه	۰/۶۳۶	۰/۶۳۶
احتمالاتی	۱۸ ثانیه	۱۶۷ ثانیه	۱۴ ثانیه	۰/۱۰۱ ثانیه	۰/۱۰۱	۰/۱۰۱

در خاتمه، لازم به ذکر است که متأسفانه با توجه به عدم دسترسی به پیاده‌سازی سایر روش‌های ارائه شده برای همانندجويي در زبان فارسي، عدم دسترسی به مجموعه داده مورد استفاده برای آزمایش اين روش‌ها و همچنین، فقدان نتایج ارزیابی اين روش‌ها روی

مجموعه داده مورد بررسی در این مقاله، امکان مقایسه روش‌های پیشنهادی با این روش‌ها ممکن نیست.

۴. نتیجه‌گیری

در این مقاله دو روش همانندجویی جدید _ روش معنایی و روش احتمالاتی_ با هدف تشخیص متون بازنویسی شده در زبان فارسی ارائه شده است. در هر دو روش پیشنهادی، ابتدا پیش‌پردازش‌های مختص زبان فارسی بر روی متون مورد آزمایش انجام می‌شود. در روش همانندجویی معنایی پیشنهادی از ابزار لغتنامه برای محاسبه همانندی جملات بازنویسی شده استفاده شده است. در روش همانندجویی احتمالاتی، همانندی واژگان بر اساس تابع احتمالی که با انکا به هر خدادای آن‌ها تعریف شده، محاسبه شده است. روش احتمالاتی پیشنهادی اولین روش همانندجویی احتمالاتی ارائه شده برای زبان فارسی بوده و روش معنایی پیشنهادی در مقایسه با روش‌های معنایی موجود از معیارهای جدیدی برای بررسی همانندی متون استفاده می‌کند. علاوه بر این، در حالی که در سایر روش‌های موجود همانندی هر جمله از متن مشکوک با هر جمله از متن منبع احتمالی به صورت مستقل بررسی می‌شود، در روش‌های پیشنهادی همانندی جملات همسایه نیز در بررسی همانندی دو جمله در نظر گرفته شده است. نتایج پیاده‌سازی و آزمایشات صورت گرفته بر روی روش‌های پیشنهادی در حالی که بیانگر کیفیت مناسب و تقریباً یکسان هر دو روش ارائه شده است، نشان می‌دهد که روش احتمالاتی پیشنهادی از کارایی بسیار بهتری برخوردار است و در زمان بسیار کمتری می‌تواند نتیجه همانندجویی را ارائه نماید.

فهرست منابع

استیری، احمد، محسن کاهانی، رضا سعیدی، و احسان عسگریان. ۱۳۹۱. طراحی ابزار پارسی‌زبان فارسی. اولین کنفرانس پردازش خط و زبان فارسی. سمنان.

References

- Adam, A. R. 2014. Plagiarism detection algorithm using natural language processing based on grammar analyzing. *Journal of Theoretical & Applied Information Technology* 63 (1): 168-178.
- AleAhmad, A., H. Amiri, E. Darrudi, M. Rahgozar, and F. Oroumchian. 2009. Hamshahri: A Standard Persian Text Collection. *Knowledge-Based Systems* 22 (5): 382–387.
- Alzahrani, S. M., and N. Salim2009 .. On the use of fuzzy information retrieval for gauging similarity of Arabic documents. *Second International Conference on Applications of Digital Information and Web*

- Technologies*, 2009. ICADIWT'09. Second International Conference on the. IEEE: 539-544.
- Alzahrani, S. M., N. Salim, and A. Abraham2012 .. Understanding plagiarism linguistic patterns, textual features, and detection methods. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 42 (2): 133-149.
- Alzahrani, S. M., N. Salim, and V. Palade2015 .. Uncovering highly obfuscated plagiarism cases using fuzzy semantic-based similarity model. *Journal of King Saud University-Computer and Information Sciences* 27 (3): 248-268.
- Gharavi, E., K. Bijari, K. Zahirnia, and H. Veisi. 2016. A Deep Learning Approach to Persian Plagiarism Detection. *Working notes of FIRE 2016-Forum for Information Retrieval Evaluation*. Tehran, Iran. pp.:154-159.
- Gipp, B., and N. Meuschke. 2011. Citation pattern matching algorithms for citation-based plagiarism detection: greedy citation tiling, citation chunking and longest common citation sequence. *Proceedings of the 11th ACM symposium on Document engineering*: 249-258.
- Khodaparasti, F. 1997. *A Comprehensive Dictionary of Persian Synonyms and Antonyms*. Shiraz: Danesh-Nameh Farsi Publication.
- Koberstein, J., and Y.-K. Ng. 2006. Using word clusters to detect similar web documents. *International Conference on Knowledge Science, Engineering and Management*. Guilin City, China. pp. 215-228.
- Le, Q. and T. Mikolov. 2014. Distributed representations of sentences and documents. *In International Conference on Machine Learning* Beijing, China. pp. 1188-1196.
- Li, Y., D. McLean, Z. A. Bandar, J. D. O'shea, and K. Crockett. 2006. Sentence similarity based on semantic nets and corpus statistics. *IEEE transactions on knowledge and data engineering* 18 (8): 1138-1150.
- Mahdavi, P., Z. Siadati, and F. Yaghmaee. 2014. Automatic external Persian plagiarism detection using vector space model. *In Computer and Knowledge Engineering (ICCKE), 2014 4th International eConference on Computer and Knowledge Engineering*. Mashhad, Iran. pp. 697-702.
- Mahmoodi, M. and M. M. Varnamkhasti. 2014. Design a Persian Automated Plagiarism Detector (AMZPPD). *International Journal of Engineering Trends and Technology* 8 (8): 465-467.
- Mashhadirajab, F., and M. Shamsfard. 2016. A Text Alignment Algorithm Based on Prediction of Obfuscation Types Using SVM Neural Network. *Working notes of FIRE 2016-Forum for Information Retrieval Evaluation*. Tehran, Iran. pp.: 167-171.
- Mikolov, T., I. Sutskever, K. Chen, G. S. Corrado, and J. Dean. 2013. Distributed representations of words and phrases and their compositionality. *In Advances in neural information processing systems*. Lake Tahoe. pp.: 3111-3119.
- Minaei, B., and M. Niknam. 2016. An n-gram based Method for Nearly Copy Detection in Plagiarism Systems. *Working notes of FIRE 2016-Forum for Information Retrieval Evaluation*. Tehran, Iran. pp.: 172-175.
- Pothast, M., B. Stein, A. Barrón-Cedeño, and P. Rosso. 2010. An evaluation framework for plagiarism detection. *In Proceedings of the 23rd international conference on computational linguistics: Posters*. Association for Computational Linguistics. Posters. Beijing, China. pp. 997-1005. Association for Computational Linguistics.
- Pothast, M., M. Hagen, T. Gollub, M. Tippmann, J. Kiesel, P. Rosso, E. Stamatatos, and B. Stein. 2013. *Overview of the 5th International Competition on Plagiarism Detection*. In: Forner, P., Navigli, R., Tufis, D. (eds.) Working Notes Papers of the CLEF 2013 Evaluation Labs.
- Rafieian, S. 2016. Plagiarism checker for Persian (PCP) texts using hash-based tree representative fingerprinting. *Journal of AI and Data Mining* 4 (2): 125-133.
- Stamatatos, E. 2011. Plagiarism detection using stopword n-grams. *Journal of the American Society for Information Science and Technology* 62: 2512-2527.

Taghva, K., R. Beckley, and M. Sadeh. 2003. A list of Farsi stopwords. *Technical Report 2003-01, Information Science Research Institute, University of Nevada, Las Vegas*, July 2003.

Yerra, R., and Y.-K. Ng. 2005. A sentence-based copy detection approach for web documents. *International Conference on Fuzzy Systems and Knowledge Discovery*. Changsha, China. pp.: 481-482.

نصرالله پاکنیت

متولد سال ۱۳۶۵، دارای مدرک دکتری در رشته ریاضی از دانشگاه شهید بهشتی تهران است. ایشان هم‌اکنون استادیار پژوهشکده علوم اطلاعات پژوهشگاه علوم و فناوری اطلاعات ایران (ایراندак) است. رمزنگاری، الگوریتم‌ها و متن کاوی از جمله علایق پژوهشی وی است.



آزاده محبی

متولد سال ۱۳۵۷، دارای مدرک دکتری در رشته مهندسی طراحی سیستم‌ها از دانشگاه واترلو کاناداست. ایشان هم‌اکنون استادیار پژوهشکده فناوری اطلاعات پژوهشگاه علوم و فناوری اطلاعات ایران (ایراندак) است.

داده کاوی، سیستم‌های هوشمند، بازشناسی الگو، متن کاوی و بازیابی اطلاعات از جمله علایق پژوهشی وی است.

