

تشخیص خودکار جنسیت نویسنده در متون فارسی

مهردی مرادی و محمد بحرانی

مرکز زبان‌ها و زبان‌شناسی، دانشگاه صنعتی شریف، تهران، ایران

چکیده

با گسترش روزافزون استفاده از اینترنت، شاهد تبادل هزاران گیگابایت اطلاعات متنی در فضای مجازی هستیم. فضای سایبر این امکان را به اشخاص می‌دهد که هویت حقیقی خود را مخفی کنند و با هویت ساختگی جدیدی وارد آن شوند. از این‌رو اهمیت حفظ امنیت این فضا، کنترل بر محتوای تولیدشده توسط کاربران و شناسایی مشخصات تولیدکنندگان محتوا هر روز پررنگ‌تر می‌شود. موضوع مورد بررسی در این پژوهش که مربوط به حوزه شناسایی نویسنده است، شناسایی خودکار جنسیت نویسنده متن فارسی است. به‌منظور شناسایی جنسیت، با توجه به مطالعات زبان‌روان‌شنختی صورت گرفته،^{۴۸} ویژگی روان‌شنختی و سبک‌شناسی تعریف شد. دو پیکره متنی جهت آموزش طبقه‌بندها تهیه و سپس برای شناسایی جنسیت، سه الگوریتم یادگیری ماشینی مختلف (ماشین‌بردار پشتیبان، بیز ساده و درخت تصمیم) طراحی شد. نتایج اعتبارسنجی متقابل ده‌تایی نشان داد که بیشترین دقت مربوط به طبقه‌بند درخت تصمیم با دقت ۷۳/۸٪ است.

وازگان کلیدی: تشخیص جنسیت، شناسایی نویسنده، متن کاوی.

۱- مقدمه

عصر ارتباطات و گسترش استفاده از نامه‌های الکترونیکی، پیام‌های فوری (IM)، اسناد، وبلاگ‌ها، مقالات خبری، صفحات خانگی، تالارهای گفتگو و شبکه‌های اجتماعی، متن را به اصلی‌ترین وسیله ارائه و انتقال اطلاعات تبدیل کرده است.

جدید جهت ردیابی هویت بزه کاران ضروری به‌نظر می‌رسد. علاوه‌بر این تشخیص جنسیت نویسنده می‌تواند کاربردهای تجارتی متعددی دیگری نیز داشته باشد. برای مثال با مشخص شدن جنسیت نویسنده می‌توان فهمید که زنان یا مردان بیش‌تر درباره چه موضوعات یا محصولاتی صحبت می‌کنند و از چه خدماتی یا کالاهایی بیزارند. دسترسی به این اطلاعات برای تبلیغات هدفمند بسیار حائز اهمیت است (آرجون و همکاران، ۲۰۱۰). در حوزه ترجمه ماشینی^۲، وقتی قرار است ترجمه بین دو زبانی که نظام ضمیرهایشان متفاوت است، انجام شود مشخص بودن جنسیت ضمیر، دقت ترجمه را افزایش خواهد داد (برای مثال ترجمه جمله "من تنها هستم" بسته به جنسیت نویسنده، در ایتالیایی دو جمله "Sono solo" برای مرد و "Sono sola" برای زن خواهد بود). کاربرد شناسایی جنسیت از دیدگاه علوم اجتماعی و تعیین خصوصیات جمعیت‌شناسی محتوای تولیدشده در اینترنت نیز می‌تواند کاربردی باشد. مطالعات

گمنامی^۱ به عنوان یکی بارزترین ویژگی‌های جامعه مجازی، (زنگ و همکاران، ۲۰۰۶) از یکسو امکان بیان آزادانه عقاید و نظرات و از سوی دیگر امکان جرایم اینترنت را فراهم می‌سازد. بی‌چهرگی و بی‌نامی افراد در اینترنت نه تنها پیگرد قانونی جرم و مجرمان را در فضای رایانه‌ای مشکل می‌سازد، بلکه زمینه گسترش بیش‌تر آن را نیز فراهم می‌کند. مجرمان اینترنتی برای ناشناس‌ماندن، از سرورهای گمنام‌کننده استفاده می‌کنند و یا این‌که با ارائه اطلاعات نادرست در مورد جنسیت، مکان، سن و ملیت خود دست به اقدامات خراب‌کارانه می‌زنند. از این‌رو استفاده از روش‌های

²Machine translation

^۱Anonymity

با گسترش رایانه، استفاده از ویژگی‌های سبک‌شناسی برای شناسایی نویسنده بیش از پیش مورد توجه پژوهش‌گران قرار گرفت، به طوری که تاکنون بیش از هزار ویژگی سبک‌شناسی مانند ویژگی‌های واژه‌بنیاد، نویسه‌بنیاد^۹ (به عنوان مثال (بول، ۱۹۹۴)) و نیز ویژگی‌های مبتنی بر کلمات دستوری (به عنوان مثال موستلر و والاس) (موستلر و والاس، ۱۹۸۴) و عالیم نگارشی^{۱۰} (باین و همکاران، ۲۰۰۲) برای این منظور تعریف شده است. هر چند پژوهش‌های بسیار زیادی بر روی زبان انگلیسی صورت گرفته و نتایج قابل قبولی نیز به دست آمده است (راچاری و همکاران، ۲۰۱۲) ولی با این وجود کارهای محاسباتی صورت گرفته بر روی شناسایی نویسنده زبان فارسی بسیار محدود و پراکنده بوده است (زینب فرهمند پور و همکاران، اسفند ۹۰). تاکنون روش‌های مختلفی برای شناسایی نویسنده استفاده شده است. پژوهش‌های نخستین در این حوزه بیشتر معطوف به استفاده از هیستوگرام توزیع طول کلمات (مننهال، ۱۸۸۷)، طبقه‌بندهای بیزی (موستلر و والاس، ۱۹۸۴)، تحلیل مؤلفه‌های اصلی^{۱۱} (بوروز، ۱۹۸۴)، تحلیل خوش^{۱۲} (هولمز، ۱۹۹۲) و غیره اشاره کرد. پژوهش‌های سخت‌افزاری و افزایش قدرت پردازش رایانه‌ها، پژوهش‌های این حوزه را به سوی استفاده از تکنیک یادگیری ماشین مانند درخت تصمیم^{۱۳} (آپت و همکاران، ۱۹۹۸) شبکه‌های عصبی^{۱۴} (تویدی و همکاران، ۱۹۹۶)، ماشین‌بردار پشتیبان^{۱۵} سوق داد (دیدربیج و همکاران، ۲۰۰۰).

مسئله مورد کنکاش در این پژوهش بررسی تمایز یا عدم تمايز زبان زنان و مردان است، اینکه جنسیت نمودی در سبک زبانی افراد دارد یا نه و کدام ویژگی‌های زبانی نقش پرنگ‌تری در تمايز زبان این دو جنس دارند. هر چند این تفاوت به قدری نیست که ارتباط بین زنان و مردان را مختلط کند، ولی همان‌طور که نتایج پژوهش‌ها نشان می‌دهد، زنان و مردان هر کدام گونه متفاوتی از زبان را به کار می‌برند. طی چند دهه گذشته، پژوهش‌گران از زوایای مختلفی، مسئله

زبان‌شناختی بر روی تغییرات زبان زنان و مردان در بازه‌های زمانی یا در حوزه‌های مختلف از کاربردهای دیگر شناسایی جنسیت نویسنده خواهد بود.

مطالعات روان‌شناختی نشان می‌دهد که کلمات مورد استفاده هر فرد بیان‌گر ویژگی‌های شخصیتی و روانی آن فرد است (پنباکر و همکاران، ۱۹۹۹)، (استیرمن و همکاران، ۲۰۰۱). نتایج پژوهش‌های روان‌شناسان نشان می‌دهد که ویژگی‌های سبک‌شناسی^۱ هر شخص (مانند کاربرد ضمایر، حروف ربط و یا حروف اضافه) با رفتارها و احساسات در ارتباط است (پنباکر، ۲۰۰۳). پژوهش‌گران از این ویژگی‌های زبان‌شناختی به عنوان ابزاری قانونی^۲ جهت شناسایی نویسنده، جنسیت، سن و یا سطح تحصیلات او استفاده می‌کنند.

۲- مروجی بر ادبیات

تشخیص جنسیت نویسنده متن، در حوزه کارهایی قرار می‌گیرد که مربوط به شناسایی نویسنده^۳ (دول و همکاران، ۲۰۰۱) یا تصدیق نویسنده^۴ است

(کوپل و همکاران، ۲۰۰۹). در فرایند شناسایی نویسنده، پژوهش‌گر به دنبال یافتن هویت واقعی نویسنده‌ای است که هویتش را مخفی نگاه داشته است.

نخستین پژوهش‌های کمی مربوط به شناسایی نویسنده در سال ۱۸۷۷ توسط مندن هال هوشمناس اهل اوهايو صورت گرفت، که پیشنهاد کرد که از توزیع طول کلمات^۵ به عنوان ویژگی وابسته به نویسنده استفاده شود (مننهال، ۱۸۸۷). وی در سال ۱۹۰۱ از این تکنیک برای شناسایی نویسنده اشعار مورد تردید شکسپیر بیکوئن استفاده کرد (مننهال، ۱۹۰۱). از پیش‌گامان رویکرد آماری به مسئله سبک‌شناسی در عصر رایانه، موستلر و والاس بودند که در سال ۱۹۶۴ از لغات دستوری^۶ و تحلیل بیزی^۷ (طبقه‌بندی بیز ساده) برای شناسایی هویت نویسنده‌گان مقالات فدرالیست^۸ استفاده کردند (موستلر و والاس، ۱۹۶۴).

تشویق مردم این ایالت به امضای قانون اساسی پیشنهادی برای ایالات متحده در کنوانسیون ۱۷۸۷ تو شته شدند، پولیسوس، نام مستعار نویسنده‌گان این مقالات بود. (ویکی پدیا)

^۹Character-based

^{۱۰}Punctuation

^{۱۱}Principle component analysis

^{۱۲}Cluster analysis

^{۱۳}Decision tree

^{۱۴}Neural networks

^{۱۵}Support vector machine

^۱Linguistic style

^۲Forensic tools

^۳Authorship identification

^۴Authorship verification

^۵Word-length distribution

^۶Function words

^۷Bayesian analysis

^۸فدرالیست مجموعه‌ای از ۸۵ مقاله است که در سال‌های ۱۷۸۷ و ۱۷۸۸ میلادی در دو نشریه در شهر نیویورک برای



موضوع را در مقاله‌ای فهرست کرده است (داوری اردکانی، ۱۳۸۷). در این بین، از جمله پژوهش‌هایی که موضوع را نه از دیدگاه روان‌شناختی و اجتماعی بلکه از نگاه زبان‌شناختی (بررسی نظام ساختاری زبان از نظر انعکاس موضوع جنسیت) مورد کنکاش قرار داده‌اند، می‌توان به بررسی جنسیت در واژگان (فارسیان، ۱۳۷۸)، نگاه مقابله‌ای به زبان فارسی و انگلیسی (چاکانی، ۲۰۰۰) و جنسیت و شمول معنایی (شجاع‌رضوی، ۱۳۸۶) اشاره کرد.

ما در این پژوهش با تعریف ^{۴۸} ویژگی مختلف، توانستیم با دقت به نسبه بالایی، جنسیت نویسنده را تشخیص دهیم.

۳- تبیین مسئله

مسئله تشخیص جنسیت نویسنده، نوعی مسئله طبقه‌بندی دوطبقه^۱ است. که هدف در این مسئله قراردادن متن بی‌نام e در یکی از طبقه‌های {زن، مرد} است (رابطه ۱).

$$\left. \begin{array}{l} \text{اگر نویسنده } e \text{ زن باشد کلاس } + \\ \text{اگر نویسنده } e \text{ مرد باشد کلاس } - \end{array} \right\} \quad (1)$$

برای بررسی فرض شماره ۱، باید ویژگی‌های تعریف شوند که در بیشتر متنون نوشته شده توسط زنان یا متون نوشته شده توسط مردان به طور نسبی ثابت باشند. پس از مشخص شدن فضای ویژگی‌ها، هر متن e را می‌توان به صورت برداری متشكل از d بعد که در آن d تعداد کل ویژگی‌ها است، نشان داد. با داشتن مجموعه‌ای از متون از قبل دسته‌بندی شده، طبقه‌بند آموزش داده شده و سپس از آن برای دسته‌بندی شده، طبقه‌بندی متنون بدون برچسب استفاده می‌شود. بیان مسئله به زبان ریاضی عبارت است از آموزش طبقه‌بند $y=f(x)$ ، از روی دادگان آموزش $D=(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$. $X=\{x_i, i=1, 2, \dots, N\}$ مجموعه از نمونه‌ها است که در آن $x_i=[x_{i1}, x_{i2}, \dots, x_{id}]$ برداری متشكل از d بعد است. اگر $y_i \in \{y_i, i=1, 2, \dots, N\}$ نشان‌دهنده مجموعه برچسب باشد، $y_i \in \{+1, -1\}$ نشان‌دهنده طبقه -1 (مرد) و طبقه $+1$ (زن) و N تعداد نمونه در مجموعه داده است. در کل شناسایی جنسیت نویسنده را می‌توان به چهار مرحله تقسیم کرد شکل (۱).

۱. تهیهٔ پیکرهٔ دارای برچسب جنسیت

^۸Binary Classification problem

تفاوت بین زنان و مردان و نیز مسئله جنسیت و زبان را مورد پژوهش قرار داده‌اند (تالبو، ۱۹۹۸). این نوع پژوهش‌ها که در آغاز بیشتر معطوف به بررسی تأثیر متغیر جنسیت در رفتار کلامی افراد در سطح آوای و نیز شیوه تعامل بودند (ووداک و همکاران، ۲۰۰۷). با انتشار مقاله روبین لیکاف ("جایگاه زنان در زبان") در ۱۹۷۵ بدل به نقطه عطفی در مطالعات زبان و جنسیت شد. لیکاف در این مقاله با بر شمردن ویژگی‌های واژگانی، نحوی و کاربردشناختی^۲، مانند استفاده از واژه‌های خاص، پوچوازه^۳ ها، ضمیمه‌های سؤالی^۴، عبارات غیر صریح^۵ و قواعد از نوع تصحیح افراطی^۶ سعی در شناسایی سبک نگارش زنان داشت (لیکاف، ۱۹۷۵). تالبوت در کتاب خود می‌گوید: الگوهای زبانی در گفتار زنان و مردان، نشان‌گر طبقه اجتماعی آنان است. در محیط کار، زنان طبقه پایین تر هنگام گفت گو با رؤسایشان از زبان مؤدبانه‌تری استفاده می‌کنند (تالبوت، ۱۹۹۸). طبق نتایج پژوهش مولاک و همکاران، در گفتگوهای دو نفره، جملات پرسشی بیشتر در کلام زنان و جملات امری بیشتر در کلام مردان دیده می‌شود (مولاک، ۱۹۹۸). باید توجه کرد که پژوهش‌گران بین مفهوم جنس^۷ و جنسیت^۸ تفاوت قائلند. جنس به ابعاد بیولوژیکی مردانگی و زنانگی فرد اشاره دارد؛ در حالی که جنسیت به صفات و ویژگی‌های اجتماعی دو جنس اطلاق می‌شود (اوونگر، ۱۹۷۹). جنس هر فرد از بد و تولدش مشخص است؛ حال آن که جنسیت را جامعه تعیین می‌کند؛ که به ویژگی‌های شخصی و روانی شخص دلالت دارد. به عبارت دیگر هر زنی رفتار زنانه ندارد و هر مردی نیز لروماً مردانه رفتار نمی‌کند. مسئله مورد بررسی این پژوهش تفاوت‌های زبانی وابسته به جنسیت است و به تفاوت‌های مرتبط با جنس پرداخته نخواهد شد.

۱-۲- جنسیت و زبان فارسی

هر چند کارهایی بر روی زبان‌های دیگر انجام شده، ولی در مورد شناسایی خودکار جنسیت نویسنده در زبان فارسی کار چندان مهمی صورت نگرفته است. مروری بر کارهای (غیر محاسباتی) انجام شده بر روی زبان فارسی نشان از انجام پژوهش‌هایی بر روی گونه نوشتاری و گفتاری فارسی دارد. نگار داوری اردکانی مقالات و پایان‌نامه‌های مرتبط با این

^۱ Pragmatic

^۲ Expletive

^۳ Tag questions

^۴ Hedges

^۵ Hypercorrect

^۶ Sex

^۷ Gender

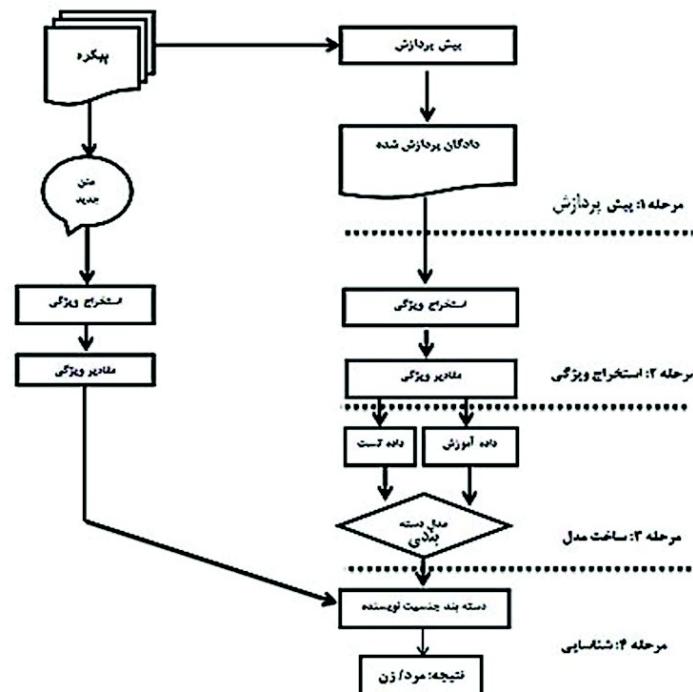
که متون موجود در این پیکره فاقد برچسب مشخص کننده جنسیت بودند، با توجه به اسم نویسنده داستان یا رمان، به صورت دستی تمامی متون موجود در بخش کتابهای داستانی این پیکره به دو گروه زن و مرد تقسیک شد. بخش دیگری از داده‌ها نیز از رمان‌ها، داستان‌های بلند و کوتاه‌ی که به صورت پی‌دی‌اف در اینترنت موجود بودند تهیه گشت. برای حذف تأثیر عامل جنسیت مترجم بر روی متن اصلی اثر، تمامی داستان‌ها و رمان‌های غیر فارسی از مجموعه مورد نظر حذف شد. پس از تهیه پیکره به منظور حذف عامل تعداد متن بر روی استخراج ویژگی‌ها، در هر دو دسته زن و مرد تعداد مساوی ۲۵۴ داستان قرار داده شد.

۲. شناسایی ویژگی‌های زبانی متمایز کننده جنسیت
۳. استخراج خودکار مقادیر هر ویژگی از هر متن
۴. ساخت مدل دسته‌بندی برای شناسایی جنسیت نویسنده در متون هدف

۴- تهیه پیکره آموزشی (دارای برچسب جنسیت)

۱-۴ - پیکره بی‌جن‌خان (متون ادبی)

بخشی از داده‌های مورد استفاده در این پژوهش از پیکره متنی بی‌جن‌خان (بی‌جن‌خان، ۱۳۸۶) به دست آمد. از آن جا



(شکل -۱): فرآیند شناسایی جنسیت نویسنده

بود، ولی از آن‌جا که کاربران ایرانی به طور معمول جملات دیگران را توبیت کرده یا در دیوار^۴ خود می‌نویسند، تصمیم گرفته شد که از نظرات کاربران در سایت هلوکیش استفاده شود (سایت هلوکیش، ۲۰۱۲). برای خوش^۷ در این سایت از برنامه بیوتیفل سوپ^۸ که به صورت کتابخانه‌ای در محیط

۲-۴ - پیکره متون گفتاری

برای تهیه این پیکره، از رویکرد وب برای پیکره^۱ استفاده شد. مهم‌ترین چالش، شناسایی سایتی فارسی بود که نخست محتوای متنی آن توسط خود کاربر نوشته و دوم نام نویسنده هر متن نیز مشخص شده باشد. در ابتدا تصمیم بر استفاده از توییت^۳ های سایت توییتر^۳ یا استاتوس^۹ های سایت فیس‌بوک^۵

⁴ Statues = وضعیت

⁵ www.facebook.com

⁶ Wall

⁷ Crawling

⁸ Beautiful Soup

¹ Web for corpus

² Tweet

³ www.tweeter.com

تعداد نویسه‌های ویژه (# و %) و غیره می‌شود (مریم، ۱۹۹۶). ویژگی‌های مبتنی بر واژه شامل یازده معیار آماری مانند غنای واژگانی، معیار يول (K) و معیار سیمپسون (D) هستند. پژوهش‌های چهار دهه گذشته نشان می‌دهد که شرایط جسمی و روانی افراد در واژه‌گزینی آن‌ها تأثیر دارد (گوتسچالک، ۱۹۹۶). تحلیل‌های انجام گرفته بر روی متون نشان داده است که تعداد کلمات مثبت (مانند عشق، خوب) در نوشته‌های افراد خوش‌قلم بیشتر به چشم می‌خورد؛ این افراد از کلمات دارای بار معنایی منفی (مانند زشت، کریه) در حد متعارف استفاده می‌کنند و کلمات شناختی (مانند دانستن، علت) را فراوان مورد استفاده قرار می‌دهند (پنباکر و همکاران، ۲۰۰۷). ویژگی‌های نحوی، سبک نگارشی نویسنده را در سطح جمله نشان می‌دهند. این ویژگی‌ها شامل تعداد علایم نگارشی (مانند ویرگول، نقطه، علامت تعجب و غیره) است. به علت تفاوت زنان و مردان در استفاده از علایم نگارشی، از این ویژگی‌ها می‌توان برای تشخیص جنسیت نویسنده استفاده کرد. به عنوان مثال طبق پژوهش‌ها مولاک، بسامد علامت سؤال در متون زنان نسبت به مردان بیشتر است (مولاک و همکاران، ۱۹۹۰).

به کمک ویژگی مبتنی بر ساختار، نویسنده چیدمان نوشته خود را سازماندهی می‌کند. افراد عادت‌های متفاوتی در سازماندهی متن خود دارند. ویژگی‌های مانند میانگین طول جمله، تعداد خطوط، تعداد خطوط خالی و غیره جزء ویژگی‌های ساختاری یک متن شمرده می‌شوند.

لغات دستوری، لغاتی هستند که معنای واژگانی کمی دارند، ولی کاربرد دستوری زیادی داشته و برای نشان دادن روابط دستوری مابین کلمات استفاده می‌شود. از این ویژگی‌ها می‌توان به ضمایر، اصوات و حروف اضافه اشاره کرد.

نشانه‌های روانی‌زبانی، مجموعه کلماتی هستند که بیان کننده ویژگی‌های شخصیتی و روانی شخص (مانند بسامد استفاده از صفات مثبت یا منفی، رنگ‌ها، کلمات ریک) است.

۵-۱- استخراج خودکار و بازنمایی ویژگی‌ها

برای استخراج ویژگی‌های روانی‌زبانی جدول (۳) مانند تعداد صفات و تعداد قیدها و ضمایر، از برچسب‌زن اجزای کلام با مدل مارکوف مخفی مرتبه دو، که از روی پیکره برچسب خورده بی‌جن‌خان (بی‌جن‌خان، ۱۳۸۶) آموزش دیده شده بود استفاده شد. فهرست کلمات مربوط به ضمایر

برنامه‌نویسی پایتون وارد^۱ شود و قابلیت‌های بالایی در پارس صفحات HTML/XML دارد استفاده شد. برای استخراج نظرات مرتبط با نظردهنگان زن و مرد، ابتدا فهرستی تفکیک شده از اسمی فارسی زن و مرد تهیه شد؛ سپس نام نویسنده نظر را این فهرست اسامی تطبیق داده شده و نظرات بر حسب این فهرست تفکیک شده، در دو دسته زن و مرد قرار گرفت.

(جدول-۱): پیکره داستان و رمان فارسی

میانگین تعداد کلمه در هر سند	تعداد سند	
۱۷۷۸-	۲۵۴	نویسنده مرد
۲۸۶۹-	۲۵۴	نویسنده زن
۲۳۲۲۵	۵۰۸	کل

(جدول-۲): پیکره گفتاری نظرات

میانگین تعداد کلمه در هر سند	تعداد سند	
۸۵	۱۱۸۹	نویسنده مرد
۸۸	۱۱۸۹	نویسنده زن
۸۶/۵	۲۳۷۸	کل

از آن‌جا که بسیاری از متون فارسی با صفحه کلید عربی و یا غیراستاندارد نوشته شده و می‌شوند، احتمال وجود نویسه‌های غیر فارسی (برای مثال عربی یا اردو) در متون وجود دارد که در صورت عدم هنجراسازی این نویسه‌ها، نتایج پردازش‌های انجام‌شده بر روی متون قابل اطمینان نخواهند بود. قبل از انجام پژوهش، تمامی نویسه‌های غیرفارسی به معادل فارسی تبدیل شدند. جداول (۱) و (۲) مشخصات این دو پیکره را نشان می‌دهد.

۵- انتخاب مجموعه ویژگی

با توجه به ادبیات پژوهش و بر پایه پژوهش‌های روان‌شناسی، پنج مجموعه ویژگی مرتبط با جنسیت شامل: (۱) نویسه‌بنیاد (۲) واژه‌بنیاد (۳) نحوی (۴) ساختاربنیاد و (۵) کلمات دستوری برای هر سند محاسبه شده است. جدول شماره ۳ فهرست ۴۸ ویژگی استخراج شده را نشان می‌دهد. ویژگی‌های مبتنی بر نویسه شامل شش ویژگی سبک‌شناسی هستند که به طور گستردگی در مسائل تشخیص نویسنده به کار می‌روند و شامل ویژگی‌هایی مانند تعداد نویسه خالی،

^۱Import



۶- بیز ساده به عنوان الگوریتم دسته‌بندی

طبقه‌بندی‌های بیز ساده، سرعت محاسباتی بالای داشته و با داده‌های آموزشی کم نیز دقت خوبی نشان می‌دهند. برای فرموله کردن تشخیص جنسیت نویسنده با استفاده از مدل استاندارد بردارستند به صورت زیر عمل می‌کنیم: هر متن را به صورت $D = (F_1, F_2, \dots, F_n)$ در نظر می‌گیریم، که در آن F_i ویژگی مورد نظر (مانند طول کلمه، تعداد صفت و غیره) است با داشتن این بردار، هدف ما تشخیص جنسیت نویسنده آن یعنی G است:

$$G \in \{\text{male, female}\} \quad (3)$$

جنسیت G از طریق بیشینه کردن احتمال $P(G|D)$ به دست می‌آید. طبق قانون بیز داریم:

$$P(G|D) = \frac{P(G)P(D|G)}{P(D)} \quad (4)$$

$$P(D|G) = P(F_1, F_2, \dots, F_n|G) \quad (5)$$

با توجه به فرض بیز ساده مبنی بر استقلال متغیرها داریم:

$$P(F_1, F_2, \dots, F_n|G) = P(F_1|G)P(F_2|G) \dots P(F_n|G), \quad (6)$$

و فرمول به شکل زیر تغییر می‌کند:

$$\text{gender} = \underset{G}{\operatorname{argmax}} P(G) \prod_{i=1}^n p(F_i|G) \quad (7)$$

از آن جا که داده آموزشی ما برای دو جنس حجم یکسانی داشت، احتمال پیشین $P(G)$ برای هر دو یکسان خواهد بود.

۶- الگوریتم ADtree (درخت تصمیم تناوبی)

در الگوریتم درخت تصمیم گیری، هر کره درخت، نمایان گر یک ویژگی خاص است. در هر نقطه از پیمایش این درخت، تصمیم گیری براساس مقدار این ویژگی خاص در نمونه دسته بنده نشده صورت می‌گیرد. در کل، درخت تصمیم گیری روشی متداول است که حوزه کاربرد گسترده‌ای دارد (صفویان و لاندگرب، ۱۹۹۱). درخت تصمیم ADtree، نوع وزن دار و تعمیم‌یافته‌ای از درخت تصمیم گیری است که از دو نوع گره تشکیل شده: گره تصمیم گیری و گره پیش‌بینی. ترکیب امتیاز گره‌های پیش‌بینی پیمایش شده و گره‌های

فعالی، پرسشی، حرف ربط گروهی، صوت و حروف اضافه از واژگان زیایی فارسی به دست آمد (اسلامی و همکاران، ۱۳۸۳). برای شمارش صفات مثبت و منفی در متون، به صفات موجود در واژگان زیایی زبان فارسی برجسب مثبت (۱۸۴۰ صفت) و منفی (۱۵۳۶) داده شد و سپس این صفات در متن شمارش شد. برای استخراج رنگ‌ها از ویژگی سلسله‌مراتبی^۱ صفحات ویکی‌педیا فارسی استفاده شد (برای مثال در صفحه "رده رنگ‌ها" می‌توان نام رنگ‌های مختلف زبان فارسی را مشاهده کرد). برای استخراج کلمات مربوط به شک و تردید و قطعیت، فهرست واژگان مربوط به این دو حوزه در زبان انگلیسی از سایتها مختلف گردآوری و معادل فارسی آن‌ها نوشته و در متون شمارش شدند. فهرست کلمات رکیک با جستجو در اینترنت جمع‌آوری شد (به ضمایم مراجعه شود).

استخراج کننده ویژگی برای هر مستند متنی، یک بردار ۴۸ بعدی جهت بازنمایی مقادیر تولید می‌کند. از آن جا که اعداد مربوط به ویژگی‌ها از روش‌های مختلفی به دست آمده بود، این اعداد ممکن بود از صفر تا بیست‌هزار تغییر کنند. برای مثال مقدار مربوط به تعداد کلمه برای یک مستند ممکن است ۱۴۵۴۰ باشد؛ در حالی که میانگین تعداد نویسه در کلمه برای همان مستند ۳۴ باشد. از این‌رو، برای اطمینان از این که در فرایند دسته‌بندی با تمامی مقادیر به صورت یکسان برخورد خواهد شد، تمامی مقادیر را به کمک روش هنجارسازی کمینه-بیشینه^۲ نormal کردیم تا در حد واسط صفر تا یک قرار گیرند:

$$\text{Normalized } -x_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)} \quad (2)$$

که در این فرمول: x_{ij} ویژگی زام در نمونه i و $\max(x_j)$ و $\min(x_j)$ کمترین و بیشترین مقادیر ویژگی زام هستند.

۶- روش دسته‌بندی

برای دسته‌بندی از سه دسته‌بندی بیز ساده^۳، درخت تصمیم ADtree و بردار ماشین پشتیبان^۴ که به صورت گسترش ده در مسائل دسته‌بندی متون کاربرد دارند، استفاده شد. برای دسته‌بندی از بسته یادگیری ماشین و کا استفاده شد (مارک هال و همکاران، ۲۰۰۹).

¹Hierarchical

²max-min normalization method

³Naïve Bayes

⁴Support vector machine

ادامه (جدول - ۳): مجموعه ویژگی‌ها و توضیحات

	ویژگی کلمات دستوری
تعداد ضمیر فاعلی /	F_{30}
تعداد ضمیر پرسشی /	F_{31}
حرف ربط / N	F_{32}
حرف ربط گروهی / N	F_{33}
صوت / N	F_{34}
حرف اضافه / N	F_{35}

ادامه (جدول - ۳): نشانه‌های روانی- زبانی

کلمات مربوط به ویژگی	ویژگی	
زیبا، معروف، سالم ...	صفات مثبت	F_{36}
دشمن، آسوده، غیرقانونی ...	صفات منفی	F_{37}
دوغی، عدسی، ماشی.	رنگ‌ها	F_{38}
دیوی، پفیوز، خرفت ...	کلمات رکیک	F_{39}
خوب، بد، معمولی ...	تعداد صفات	F_{40}
احمقانه، بیگمان، زیرکانه ...	تعداد قید	F_{41}
من، تو، او، ما، شما، ایشان	تعداد ضمایر	F_{42}
فرض، گمان، یحتمل	نسبت ضمایر	F_{43-46}
هیچگاه، هرگز، همیشه	شک و تردید	F_{47}
	قطعیت	F_{48}

۳-۶- ماشین بردار پشتیبان

این روش یکی از پرکاربردترین الگوریتم‌ها در حوزه شناسایی نویسنده است (دیدریج و همکاران، ۲۰۰۳). اساس این روش، یافتن بهترین ابرصفحه^۸ دارای بیشترین فاصله است، که بتواند داده‌های دو دسته را از هم تفکیک کند. این الگوریتم قادر است بدون بیش‌برازش شدن، تعداد زیادی ویژگی را در قالب یک مستقله دسته‌بندی خطی یا غیر خطی به کار گیرد. اگر ورودی این الگوریتم را بتوان به صورت خطی جدا کرده، SVM فاصله بین این دو طبقه را با جستجوی ابرصفحه بهینه جدا کننده، بیشینه می‌کند. بردار وزنی بهینه^۹ را با حل مسئله بهینه‌سازی زیر می‌توان یافت:

$$\text{Minimize } j(\omega) = \frac{1}{2} \|\omega\|^2 \quad (8)$$

به شرطی که $y_i (\omega \cdot x_i - b) \geq 1$

در مواردی که داده‌ها به صورت غیر خطی قابل جداسازی نیستند، SVM با استفاده از یک متغیر بی‌اثر^{۱۰} و اجزاء قرار گرفتن نمونه‌های آموزشی در ناحیه‌ای مابین دو ابرصفحه‌ای که از نقطه پشتیانی دو طبقه می‌گذرد، اقدام به ساختن یک حاشیه نرم^{۱۱} می‌کند (کورتکس و واپنیک،

انتهایی، تعیین کننده دسته هر نمونه است (ماسون و همکاران، ۱۹۹۱).

(جدول - ۳): مجموعه ویژگی‌ها و توضیحات

ویژگی	توضیح ویژگی
ویژگی‌های مبتنی بر نویسه	ویژگی‌های مبتنی بر نویسه
تعداد کل نویسه‌ها (C)	تعداد کل نویسه‌ها (F_1)
تعداد کل حروف الفبا (الف- ب) / C	تعداد کل حروف الفبا (الف- ب) (F_2)
تعداد کل اعداد C /	تعداد کل اعداد (F_3)
تعداد نویسه‌فاصله C /	تعداد نویسه‌فاصله (F_4)
تعداد نویسه تپ C /	تعداد نویسه تپ (F_5)
تعداد نویسه‌های ویژه C /	تعداد نویسه‌های ویژه (F_6)
ویژگی‌های مبتنی بر واژه	ویژگی‌های مبتنی بر واژه
تعداد کل کلمات (N)	تعداد کل کلمات (F_7)
میانگین تعداد نویسه در کلمه	میانگین تعداد نویسه در کلمه (F_8)
غنای واژگانی (کل لغات یکتا) / N	غنای واژگانی (کل لغات یکتا) / N (F_9)
کلمات طولانی (بزرگتر از ۳ نویسه) / N	کلمات طولانی (بزرگتر از ۳ نویسه) / N (F_{10})
کلمات کوتاه (کوچکتر از ۲ نویسه) / N	کلمات کوتاه (کوچکتر از ۲ نویسه) / N (F_{11})
هپکس لغومنا ^۱ (کلمات ۱ تکراره) / N	هپکس لغومنا ^۱ (کلمات ۱ تکراره) / N (F_{12})
هپکس دیسلگومنا ^۲ (کلمات ۲ تکراره) / N	هپکس دیسلگومنا ^۲ (کلمات ۲ تکراره) / N (F_{13})
معیار K یول ^۳	معیار K یول (F_{14})
معیار D سیمپسون ^۴	معیار D سیمپسون (F_{15})
معیار S سیشل ^۵	معیار S سیشل (F_{16})
معیار R هونور ^۶	معیار R هونور (F_{17})
ویژگی‌های نحوی	ویژگی‌های نحوی
تعداد کاما (.)	تعداد کاما (F_{18})
C / (.)	تعداد نقطه (.) (F_{19})
C / (:)	تعداد دونقطه (:) (F_{20})
C / (میکلون (:))	تعداد سمیکلون (:)) (F_{21})
C / (؟)	تعداد علامت سوال (؟) (F_{22})
C / (!)	تعداد علامت تعجب (!) (F_{23})
C / (!!!)	تعداد علامت تعجب ۳ تایی (!!!) (F_{24})
ویژگی‌های ساختاری ^۷	ویژگی‌های ساختاری ^۷
تعداد کل خط	تعداد کل خط (F_{25})
تعداد کل جملات (S)	تعداد کل جملات (S) (F_{26})
تعداد کلمه در هر جمله	تعداد کلمه در هر جمله (F_{27})
تعداد خطوط خالی / تعداد کل خطوط	تعداد خطوط خالی / تعداد کل خطوط (F_{28})
میانگین طول خطوط غیر خالی	میانگین طول خطوط غیر خالی (F_{29})

¹ Hapax legomena

² Hapax dislegomena

³ Yule's K measure

⁴ Simpson's D measure

⁵ Sichel's S measure

⁶ Honore's R measure

⁷ Structural features

⁸ Hyperplane
⁹Soft margin

الگوریتم اهمیت هر ویژگی را با محاسبه بهره اطلاعاتی آن ویژگی و با توجه به طبقه مشخص می کند. با انجام دوباره عمل دسته بندی با SVM بر روی این ۵۰ ویژگی، مشاهده شد که دقت طبقه بند ۲٪ افت داشته است. جدول (۶) فهرست ۵۰ ویژگی نخست متمایز کننده را نشان می دهد.

(جدول -۴): بعضی از نتایج به دست آمده برای زبان انگلیسی

ردیف	دسته بند	داده آموزشی	مرجع
۶۷/۷	بیز ساده	وضعیت های فیس	(جومی وهمکاران، ۲۰۱۰)
۵۹	پرسپترون	بوک	
۶۹	بیز ساده	کتاب و وبلاگ	(لای، ۲۰۱۰)
۸۲/۲۳	SVM	ایمیل های اترون	(نا چانگ و همکاران، ۲۰۱۱)
۷۶/۷۵		گروه خبری رویتر	

(جدول -۵): دقت طبقه بندی با هر کدام از ۵۰ ویژگی ها

ردیف	ویژگی	دقت (%)
۶۹/۱	مبتنی بر واژه	۶۹/۱
۵۵/۹	روانی - زبانی	۵۵/۹
۶۹/۳	مبتنی بر نویسه	۶۹/۳
۵۸/۹	نحوی	۵۸/۹
۶۳/۸	SAXATARI	۶۳/۸
۵۴/۴	دستوری	۵۴/۴
۷۳/۸	کل	۷۳/۸

۹- نتیجه گیری و بحث

این پژوهش نشان داد که به کمک ویژگی های سیکستننسی و روان شناختی جنسیت نویسنده را می توان تشخیص داد. نتیجه طبقه بندی بر روی دو پیکره نشان داد که تمایز زبانی مربوط به جنسیت نویسنده ای در پیکره مربوط به متون ادبی نسبت به پیکره مربوط به نظرات کاربران بیشتر است. دلیل این عدم تمایز هم ممکن است انتصاراتی محتوا بیان مربوط به نظرات باشد (از لحاظ حجم متون، عدم امکان بیان احساسات متفاوت، گونه زبانی دو پیکره). از بین ویژگی های مختلف طراحی شده، ویژگی های واژه بندی و نشانه های زبانی روانی تمایز دهنده ترین عوامل در دسته بندی متون بودند. به عنوان پیشنهاد برای کارهای بعدی، جهت رسیدن به دقت های بالاتر می توان ویژگی کیسه کلمات^۷ و یا دیگر ویژگی های متمایز کننده جنسیت را نیز به مجموعه ویژگی ها افزود. همچنین برای رسیدن به نتایج بهتر، از داده های آموزشی مربوط به چت های فارسی استفاده کرد. برای

⁶Status
⁷Bag of words

۱۹۹۵). در این حالت مسئله بهینه سازی به صورت زیر تغییر می کند.

$$\text{Minimize } j^*(\omega) = \frac{1}{2} \|\omega^*\|^2 + G \sum_{i=1}^N \xi_i \quad (9)$$

به شرطی که $\omega^* \cdot x_i - b \leq 1 - \xi_i$

وقتی از SVM برای حل مسائل غیرخطی استفاده می شود، حقه هسته^۱ کمک می کند تا فضای ویژگی \mathbb{X} به یک فضای بعد بالای (\mathbb{X}') نگاشت شود و ابر صفحه دارای بیشترین فاصله را در فضای جدید جستجو کند. در این مقاله برای دسته بندی از هسته PUK^۲ استفاده شده است که هم مقاوم است و هم قدرت نگاشت خوبی دارد (اوستون و همکاران، ۲۰۰۶).

۷- نتایج به دست آمده از دسته بندی

سه الگوریتم بیز ساده، درخت تصمیم ADtree و SVM را بر روی دو پیکره اجرا کردیم. برای ارزیابی مدل ها از روش ارزیابی اعتبارسنجی متقابل^۳ ده تایی استفاده شد. دقت دسته بندی بر روی پیکره رمان و داستان به ترتیب ۶۶/۳٪، ۷۳/۶٪ و ۷۱/۶٪ بودند؛ در حالی که دقت همین دسته بندها بر روی پیکره متنی نظرات کاربران به ترتیب ۵۳٪، ۶۳٪ و ۵۸/۵٪ بود شکل (۲). به منظور مقایسه نتایج حاضر با نتایج تشخیص جنسیت در زبان انگلیسی، در جدول (۴) نتایج چند نمونه پژوهش در زبان انگلیسی آورده شده است.

۸- ویژگی های متمایز کننده

به منظور بررسی اهمیت هر گروه از ویژگی های پیشنهاد شده، دسته بندی را پنج مرتبه با هر کدام از این ویژگی ها و به وسیله Adtree تکرار کردیم. همان طور که نتایج نشان می دهد، تمامی ویژگی های در میزان دقت طبقه بند دخیل بوده اند؛

ولی متمایز کننده ترین ویژگی ها به ترتیب ویژگی های مبتنی بر نویسه، مبتنی بر واژه و SAXATARI و کم تاثیر ترین ویژگی های نیز ویژگی های دستوری و روانی بوده اند جدول (۵).

به منظور انتخاب دو ویژگی برتر و کاهش فضای ویژگی^۴، از الگوریتم بهره اطلاعات^۵ استفاده شد (نجیب، ۱۹۹۹). این

¹Kernel trick

²Pearson VII Universal kernel

³Cross-validation

⁴Feature space reduction

⁵Information gain



ضمیمه الف:
معیار K یول:

$$Yules\ K = 10^4 \left(-\frac{1}{N} + \sum_{i=1}^v V_i \left(\frac{i}{N} \right)^2 \right)$$

معیار D سیمپسون:

$$Simpsons\ D = \sum_{i=1}^v V_i \frac{i}{N} \frac{i-1}{N-1}$$

معیار S سیشل:

$$Sichels\ S = \frac{\text{count of Hapax Dislegomena}}{V}$$

معیار R هونورس:

$$Honores\ R = \frac{100 \log_{10} N}{1 - \frac{\text{count of Hapax Legomena}}{V}}$$

V: تعداد کلمات یکتا

\sqrt{V} : تعداد کلمات یکتا که i مرتبه رخ داده است

N: تعداد کل کلمات

کلماتی که فقط دوبار تکرار شده‌اند: *Hapax Dislegomena*
کلماتی که فقط یکبار تکرار شده‌اند: *Legomena Hapax*

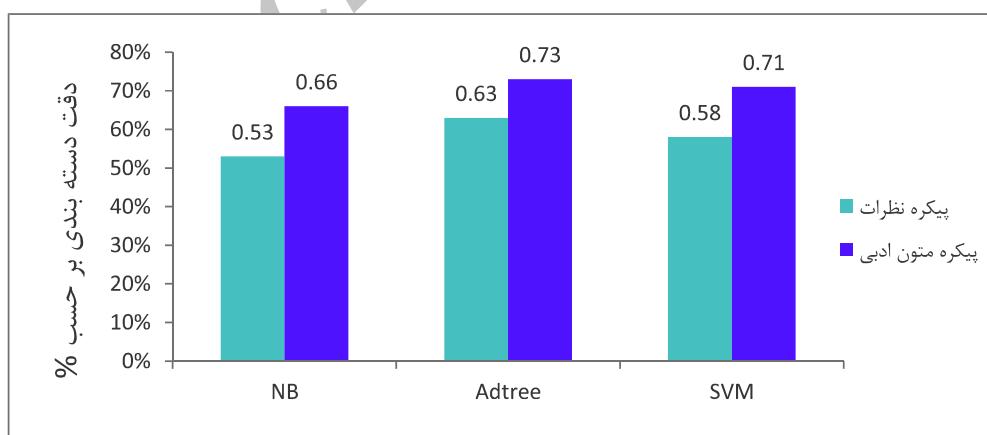
پیشرفت در حوزه شناسایی نویسنده برای زبان فارسی یکی از اولویت‌ها تعریف معیارهای ارزیابی و مقایسه روش‌های مختلف با استفاده از پیکره‌های محکزنی^۱ است. تهیه پیکره‌های مختلف زبانی با دامنه‌های (زمانی، موضوعی و غیره) مشخص در پیشرفت کار بسیار تأثیرگذار خواهد بود.

دستاوردهای این مقاله عبارتند از:

- ارائه نخستین دادگان دارای برچسب جنسیت برای زبان فارسی (دو پیکره نوشتاری و گفتاری).
- تهیه واژگان دسته‌بندی شده زبان فارسی (فهرست کلمات رکیک، رنگها، کلمات بیان‌کننده تردید و یقین، حروف ربط و غیره) و ارائه فضای ویژگی به کمک این واژگان.
- تهیه فهرست کاملی از اسمای مرد و زن فارسی
- درنهایت ارائه طبقه‌بندی‌هایی جهت طبقه‌بندی متون فارسی از نظر جنسیت نویسنده

(جدول - ۶): ده ویژگی برتر محاسبه شده با بهره اطلاعاتی

۱	تعداد نویسه
۲	تعداد کلمات
۳	غنای واژگانی
۴	کلمات دو تکراره
۵	معیار یول
۶	کلمات کوچک‌تر از دو نویسه
۷	تعداد کل حروف الفبا
۸	کلمات یک تکراره
۹	ضمیر متصل اول شخص/مابقی ضمایر
۱۰	تعداد خطوط



(شکل - ۲): الگوریتم دسته‌بندی

^۱Benchmark

ضمیمه ب (لیست کلمات):

پیوسته	همیشه	همواره	مطمئنا	یقینا	بدون شک	مسلمان	قطعا
صد در صد	هیچ	حاشا	هیچ وقت	هیچگاه	ابدا	هرگز	همه وقت

تردید	گمان	حدس	یحتمل	ممکن	گویا	احتمالا	شاید
به نظر من	محتمل	احتمالای	فرض	ظن	ممکن	ممکن	امکان

حروف ربط	زیرا	یعنی	ولو	ولیکن	ولی	و	تا	لیکن	اما	اگر	که	هر چند	هم	هکذا	گرچه	چون	چه	آنچنانکه	اما	اگر
----------	------	------	-----	-------	-----	---	----	------	-----	-----	----	--------	----	------	------	-----	----	----------	-----	-----

اصوات	کریما	دردا	دردنا	دالی	زرت	جانمی	هورا	هیهات	حیف	هان	اوای	وا	اوخ	احسنست	عجبا	آمین	آخه	بادا	به به	بالله	براؤو
کریما	دردا	دردنا	دالی	زرت	جانمی	هورا	هیهات	حیف	هان	اوای	وا	اوخ	احسنست	عجبا	آمین	آخه	بادا	به به	بالله	براؤو	

پرسشی	کجا	کجاوی	چرا	چه	آیا	آیا	کی	کی	کدام	کدامین	چند	ایا	ایا	چطور	چگونه	آیا	آیا	که
-------	-----	-------	-----	----	-----	-----	----	----	------	--------	-----	-----	-----	------	-------	-----	-----	----

رنگ	یاری	نقره‌ای	نارنجی	موشی	معز	کدامین	کدامیک	چند	ایا	ایا	چطور	چگونه	آیا	آیا	پسته‌ای	پسته‌ای	آبی	آلبالوی	ارغوانی	برگ سنجیدی	بنفس	خاصتی
رنگ	یاری	نقره‌ای	نارنجی	موشی	معز	کدامین	کدامیک	چند	ایا	ایا	چطور	چگونه	آیا	آیا	پسته‌ای	پسته‌ای	آبی	آلبالوی	ارغوانی	برگ سنجیدی	بنفس	خاصتی

۷امین کنفراس ملی سالانه انجمن کامپیوتر ایران، اسفند ۹۰.

سعیده شجاع رضوی. جنسیت و شمول معنایی، فصل نامه پازند. ۱۳۸۶. ۱۰ : سال سوم.

محرم اسلامی، مسعود شریفی آتشگاه، صدیقه علیزاده لمجیری، و طاهره زندی. واژگان زایای زبان فارسی،

۱۰- مراجع

داوری اردکانی، نگار؛ عیار، عطیه. کنکاشی در پژوهش‌های زبان‌شناسی جنسیت، مجله مطالعات راهبردی زنان، ۱۳۸۷، ۱۴۲-۴۲.

درگاه ملی آمار. ۱۳۹۱، ir. http://www.amar.org.ir

زینب فرهمند پور و همکاران. طراحی و پیاده‌سازی یک سامانه هوشمند تشخیص هویت نویسنده‌ی فارسی زبان،

فصلنامه



- ۱۰۵, p.-91-120.
- Internet World Usage Statistics, ۲۰۱۲ ,<http://www.internetworldstats.com/stats.htm>.
- Jeremy K, Zach G, David K, Machine Learning and Feature Based Approaches to Gender Classification of Facebook Statuses .۲۰۱۰ .http://thekeesh.com/c-s224n/final_writ
- Koppel, M., Schler, J., and Argamon, S. Computational methods in authorship attribution , Journal of American Society Information Science Technology .۶۰ , ۱ .۲۰۰۹ ..p9-26.
- Lai Chao-Yue Author Gender Analysis , Applied Natural Language Processing.۲۰۱۰ .
- Lakoff, R. Language and woman's place . New York : Harper and Row, 1975.
- Mason Yoav Freund and Llew The Alternating Decision Tree Algorithm, the 16th International Conference on Machine Learning .۱۹۹۹ .p.124-133.
- Mendenhall T. C. A mechanical solution of a literary problem , Popular Science Monthly .
- Mendenhall T. C. The characteristic curves of composition , Science .۹ , ۲۱۴ .۱۸۸۷ .p.237-248.
- Merriam T. Marlowe's hand in Edward III revisited , Literary and Linguistic .۱۱ , ۱ .۱۹۹۶ ..p.
- Miller Z., Dickinson B, Wei H. Gender Prediction on Twitter Using Stream Algorithms with N-Gram Character Features , International Journal of Intelligence Science .۲ .۲۰۱۲ .P.143-148.
- Mosteller F. and Wallace D. L. Inference and Disputed Authorship: The Federalist, Addison-Wesley, 1964.
- Mosteller F, Wallace DL. Applied Bayesian and Classical Inference: the case of the federalist papers , Springer series in statistic :Springer, 1984.
- Mukherjee A. , Liu B. Improving Gender Classification of Blog Authors , Empirical Methods in Natural Language Processing, ۲۰۱۰.p.۲۱۷-۲۰۷ .
- Mulac A. , Wiemann, J. M., Widenmann, S. J& ,Gibson, T. W. Male/female language differencesand effects in same-sex and mixed-sex dyads: The gender-linked language effect , Communication Monographs .۵۵ .۱۹۸۸ .p.315-335.
- Mulac A. Studley LB, Blau S. The gender-linked language effect in primary and secondary students'impromptu essays , Sex Roles .۲۳ .۱۹۹۰ ..p-۹ .۱۰
- مجموعه مقالات اولین کارگاه پژوهشی زبان فارسی و رایانه، تهران ، ۱۳۸۳ .
- محمد رضا فارسیان. جنسیت در واژگان، دانشگاه تهران، ۱۳۷۸
- محمود بی جن خان. پیکره متنی زبان فارسی ، پژوهشکده پردازش هوشمند عالیم، ۱۳۸۶ .
- Apte C, Damerau F, Weiss SM, Apte C, Damerau F, Weiss S Text mining with decision trees and decision rules, The conference on automated learning and discorery, workshop 6: learning from text and the web, 1998.
- Baayen H, van Halteren H, Neijt A, Tweedie F. An experiment in authorship attribution, The 6th international conference on the statistical analysis of textual data .St. Malo, France, 2002.
- BijanKhan M. The role of the corpus in writing a grammar: An introduction to a software , IranianJ-ournal of Linguistics, 2004.
- Burrows J. F, Word-Patterns and Story-Shapes: the Statis-tical Analysis of Narrative Style , Literary and Lingu-istic Computing, 1987, p. 61-70.
- Chakani Sarvar Language and Gender: A Contrastive View on Farsi and English DiscourseIslamic Azad University of Tabriz, 2000.
- Cortes C, Vapnik V. Support-vector networks , Machine learning, 1995, p.۱۷-۲۷۳ .
- De Vel, O., Anderson, A., Corney, M., and Mohay, G. Mining E-mail content for author identification fore-nics , SIGMOD Record, .۳۰ : ۴ ۲۰۰۱, p. 55-64.
- Diederich J, Kinder Mann J, Leopold E, Paass G. Authorship attribution with support vector machine , Applied Intelligence ;19, .۲۰۰۰ p.۲۳-۱۰۹ .
- Diederich, J., Kindermann, J., Leopold, E., and Paass, G. Authorship attribution with support vector mac-hines , Applied Intelligence .۱۹ .۲۰۰۳ .p.۲۳-۱۰۹ .
- Gottschalk LA Gleser GC. The measurement of psychological states through the content analysis of verbal behavior .Berkeley, University of California Press, 1969.
- Hall, Mark, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H. Witten. "The WEKA data mining software: an update." ACM SIG-KDD explorations newsletter 11, no. 1 (2009): 10-18. Hello kish .۲۰۱۲ .www.hellokish.org.
- Holmes D. I ,A stylometric analysis of the Qur'an scripture and related texts ,Royal Statistical Society,



مهردی مرادی مدرک کارشناسی ارشد زبان‌شناسی رایانشی خود را در سال ۱۳۹۲ از دانشگاه صنعتی شریف دریافت و مدرک کارشناسی خود را نیز از دانشگاه زنجان اخذ کرده است. از ایشان چند مقاله در نشریات داخلی و همایش‌های بین‌المللی و نیز یک فرهنگ تخصصی به چاپ رسیده است. وی هم‌اکنون مدرس دانشگاه آزاد واحد زنجان بوده و زمینه‌های پژوهشی مورد علاقه وی هست‌شناسی، تشخیص نویسنده، متن‌کاوی و ساخت پیکرهای زبانی است.

نشانی رایانامه ایشان عبارت است از:

Mehdi.moradi.cl@gmail.com



محمد بحرانی درجه دکترای خود را در رشته هوش مصنوعی در سال ۱۳۸۹ از دانشگاه صنعتی شریف و درجه کارشناسی ارشد خود را از همان دانشگاه در سال ۱۳۸۲ دریافت کرده است. وی هم‌اکنون عضو هیئت علمی گروه زبان‌شناسی رایانشی در مرکز زبان‌ها و زبان‌شناسی دانشگاه صنعتی شریف است. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: زبان‌شناسی رایانشی، پردازش زبان طبیعی، پردازش و بازناسی گفتار و مدل‌سازی زبانی. نشانی رایانامه ایشان عبارت است از:

bahrani@sharif.edu

Na Cheng, R. Chandramouli, K.P. Subbalakshmi Author gender identification from text , digital investigation .۲۰۱۱ .p.77-88.

Nacip F.A using information gain as feature weight , The 8th Turkish Symposium on Artificial Intelligence and Neural Networks IAINN .۹۹ Istanbul, Turkey. ۱۹۹۹)

Pennebaker J. W., Mehl, M. R& „Niederhoffer, K. G. Psychological aspects of natural language use: Our words, our selves., Annual Review of Psychology , ۲۰۰۳

Pennebaker JW, Chung CK, Ireland M, Gonzales A, Booth RJ. The development and psychometric properties of LIWC2007 .Austin, Texas : LIWC Inc, 2007.

Pennebaker, J. W& „King, L. A. Linguistic styles: Language use as an individualdifference .Personality and Social Psychology, 1999 .P. 6-14.

Safavian SR, Landgrebe D. A survey of decision tree classifier methodology , Cybernetics , ۳ .۱۹۹۱ . ۲۱ p .660-674.

Stirman, S.W& „Pennebaker, J.W. Word use in the poetry of suicidal and non-suicidal poets. , 63, . Psychosomatic Medicine, 2001 - .۶۲ - .p .517-522.

Symantec Internet Security Threat Report, Trends for 2010 .Security Response Publications. ۲۰۱۱ , Talbot MM Language and gender: an introduction., Wiley-Blackwell, 1998.

Tweedie FJ, Singh S, Holmes DI. Neural network applications in stylometry: the federalist papers , Computers and the Humanities. ۳۰ , ۱ .۱۹۹۶ .

Unger R. K Toward a redefinition of sex and gender , American Psychologist . ۴ . ۱۹۷۹ .p .1085-1094.

Üstün, Bülent, Willem J. Melissen, and Lutgarde MC Buydens. "Facilitating the application of Support Vector Regression by using a universal Pearson VII function based kernel." Chemometrics and Intelligent Laboratory Systems 81, no. 1 .2006. 29-40.

Wodak, Ruth & Benke, Gertrud "Gender as a Variation in Sociolinguistics " in The Handbook of Sociol-ingistics ,Cambridge : Blackwell, 2007.

Yule GU. The statistical study of literary vocabulary, Cambridge University Press, 1944.

Zheng R, Li J, Chen H, Huang Z . A framework for authorship identification of online messages: writing-style features and classification techniques .Journal of the American Society for Information Science and Technology, 2006.