

شناسائی و پوشش واحدهای خارج از واژگان در فارسی غیررسمی

داود حیدرپور^۱

کارشناس ارشد زبان‌شناسی رایانشی، دانشکده علوم و فنون نوین، دانشگاه تهران

مصطفی صالحی^۲

استادیار، دانشکده علوم و فنون نوین، دانشگاه تهران

محمود بی‌جن‌خان^۳

استاد، گروه زبان‌شناسی، دانشکده ادبیات و علوم انسانی، دانشگاه تهران

هادی ویسی^۴

استادیار، دانشکده علوم و فنون نوین، دانشگاه تهران

وحید رنجبر^۵

استادیار، دانشکده مهندسی کامپیوتر، دانشگاه یزد

چکیده

کلمات سیاق فارسی غیررسمی از نظر ساختار به دو دسته رسمی و غیررسمی تقسیم می‌شود. این کلمات و ساخت آنها را می‌توان شناسائی و تحلیل رایانه‌ای کرد، اما کلمات خارج از واژگان بسیاری نیز وجود دارد که تحت تاثیر تغییرات آوایی و یا نگارش شکسته اینترنتی (بخصوص رسانه‌های اجتماعی) به شکل متنوعی نوشته می‌شود و در واژگان رسمی و غیررسمی شناسائی شده، موجود نیست. این واحدها برای ابزارهای تحلیل‌گر رایانه‌ای غیر قابل شناسائی است، در حالی که ممکن است معادل آنها در واژگان موجود باشد. شناسائی و یا نگاشت آنها به معادلشان در واژگان امکان تحلیل را به ابزار رایانه‌ای می‌دهد. ضمن جمع آوری دادگان بیشتر زیرسیاق‌های فارسی غیررسمی به روش پیکره نمونه‌گیری که حدود پنجاه هزار قطعه شده است، در این مقاله با بررسی تغییرات آوایی، خطاهای نگارشی رایج در آنها، قواعدی استخراج شده است که با بکارگیری آنها شناسائی این کلمات برای ابزارهای تحلیل‌گر بهبود یافته است. برای یک ابزار تحلیل‌گر تصریفی این افزایش پوشش منجر به افزایش فراخوانی به میزان ۱.۲۵٪ شده است.

کلیدواژه‌ها: تحلیل تصریفی فارسی معاصر، تغییر آوایی کلمات غیررسمی، الگوریتم آوایی، فارسی غیررسمی، فارسی معاصر، کلمات خارج از واژگان.

۱. مقدمه

منظور از فارسی غیررسمی متن‌هایی است که در موقعیت‌های غیررسمی مانند گفتار محاوره‌ای و شبکه‌های اجتماعی تولید می‌شوند. تبدیل کلمه‌های رسمی به غیررسمی در زبان فارسی همیشه منجر به تولید واحد واژگانی مستقل نمی‌شود. گاهی این واژه جدید هیچ تفاوتی در تلفظ، نسبت به واژه رسمی ندارد اما در نگارش متفاوت از آن است. گاهی واژه‌های غیررسمی با نگارش‌های متفاوت نوشته می‌شود. استفاده از این تغییرات که معمولاً از الگوهای آوایی، جایگزینی نویسه‌های هم‌صدا و سایر متغیرهای تحت تاثیر نگارش اینترنتی (مثل رسانه‌های اجتماعی)، تبعیت می‌کند برای شناسایی و تحلیل تصریفی کلمات فارسی معاصر (رسمی و غیررسمی) لازم است. برای یک ابزار رایانه‌ای با منابع واژگانی محدود رسمی و غیررسمی فارسی، شناسائی و تحلیل این واحدهای خارج از واژگان امکان‌پذیر نیست. تاکنون در پژوهش‌های فارسی به دلیل تمیز ندادن واحدهای واژگانی مستقل از نگارش‌هایی که کلمات خارج از واژگان تولید می‌کند، پوشش لازم برای شناسائی این گونه نگارش‌ها بدست نیامده است. در ادامه

¹ d.heidarpour@ut.ac.ir

² mostafa_salehi@ut.ac.ir

³ mbjkhani@ut.ac.ir

⁴ h.veisi@ut.ac.ir

⁵ vranjbar@yazd.ac.ir

⁶ Character

چالش‌های پیش رو در پردازش فارسی رسمی و به ویژه غیررسمی که به طور مستقیم با مسئله واحدهای خارج از واژگان در ارتباط است بیان می‌شود.

۱.۱. فاصله‌گذاری

فاصله‌گذاری بین تک‌واژه‌ها در زبان فارسی معمولاً به درستی رعایت نمی‌شود. در موارد بسیاری هیچ چارچوب ثابتی برای استفاده از فاصله، نیم‌فاصله و اتصال وجود ندارد. این مسئله منجر به تولید گونه‌های مختلف یک کلمه چند واحدی^۱ و یا چند قطعه‌ای^۲ می‌شود. این موضوع یکی از علت‌های تنوع و یکدست نبودن نگارش فارسی در سطح کلمات است. برای مثال می‌توان به کلمه کتاب‌ها که به سه صورت **کتابها**، **کتاب‌ها** و **کتاب‌ها** نوشته می‌شود، اشاره کرد.

۱.۲. حروف غیر قطعی

برخی حروف فارسی وجودی غیر قطعی دارند؛ این حروف گاهی با حروف دیگر جایگزین می‌شوند و گاهی می‌توان آنها را حذف کرد. این پدیده به شکلی در فارسی رسمی و به شکلی دیگر در فارسی غیررسمی رخ می‌دهد (جدول ۱). همزه یکی از حروف الفبای فارسی به حساب می‌آید که به صورت مستقل و متصل در استاندارد یونیکد^۳ (عربی)، دو نویسه مجزا به حساب می‌آید (ء و ئ)، اما در زبان فارسی به شکل مستقل یک حرف محسوب می‌شود. همین‌طور این حرف همراه با واو، الف با فتحه، الف با کسره هم استفاده می‌شود که در استاندارد یونیکد هر کدام یک نویسه مستقل به حساب می‌آید. حروف هم‌صدا نیز در کلمات غیررسمی گاهی در جای یکدیگر به کار می‌روند. در سیاق فارسی رسمی و غیررسمی این تغییر، خطای املایی تلقی می‌شود اما به دلیل رخداد متناوب آن می‌بایست آن را رفع کرد تا چنین کلماتی به معادلشان در واژگان نگاشت شود.

حرف ه در نقش واکه در صورتی که در پایان یک تک‌واژه قرار بگیرد، در بسیاری از موارد، در هنگام اتصال به تک‌واژه دیگر حذف می‌شود.

گاهی به خطا حرف ه برای بازنمایی کسره اضافه (در فارسی غیررسمی) در پایان کلمه منتهی به همخوان و یا واکه ی استفاده می‌شود. مثل: جنوبه ایران / جنوب ایران.

۱.۳. تغییرات آوایی

تغییرات آوایی عمدتاً منجر به تولید واحد واژگانی مستقل از کلمات رسمی می‌شود. در مواردی نیز تغییرات عمده‌ای ایجاد نمی‌کند و صرفاً نگارش کلمه رسمی را تغییر می‌دهد. این دو دسته به این صورتند: الف- واحدهای واژگانی مستقل که از تغییر کلمه‌های رسمی به دست می‌آید و می‌بایست در واژگان وجود داشته باشد. مثل: آسمون؛ آسمان، نون؛ نان، هیچکدام؛ هیچکدام، اصاب؛ اعصاب، اگه؛ اگر. ب- واحدهای غیر واژگانی با نگارش متفاوت از رسمی. مثل: عرزش؛ ارزش، عاریایی؛ آریایی، دخدر؛ دختر، انرجی؛ انرژی، امبار؛ انبار، ایسگا؛ ایستگاه، هش؛ هشت. دسته دوم به دلیل تنوعی که در تولید و چرخش از کلمه اصلی دارد معمولاً در واژگان موجود نیست.

۱.۴. کلمات به هم چسبیده

کلمات به هم چسبیده خطای املایی رایجی است که شناسایی و تحلیل کلمات را با مشکل مواجه می‌سازد و در هر دو گونه رسمی و غیررسمی رخ می‌دهد.

^۱ MUT – Multi Units Token

^۲ MTU – Multi Tokens Unit

^۳ Unicode

کلماتی که منتهی به یکی از حروف و، ر، ز، ژ، د، ذ، ا باشد با احتمال بیشتری ممکن است به کلمه بعد از خود به شکل متصل حروف چینی شود. علت این امر یک نوع خطای شناختی^۱ است که در هنگام حروف چینی سریع رخ می‌دهد. گرچه این نوع اتصال بخش زیادی از این خطا را پوشش می‌دهد اما شامل همه آن نمی‌شود.

برخی حرف‌های اضافه و ضمائر نیز تحت تاثیر این تغییر، گاهی حروف واکه خود را در محل این اتصال از دست می‌دهند. برخی از این تغییرات نماینده دگرگونی‌های در زمانی زبان و گاه تعیین کننده سبک گوینده هستند. مانند ازین؛ از+این، ترا؛ تو+را و موارد مشابه دیگر.

۱.۵. خطای املایی

خطای املایی یکی از مشکلات اجتناب ناپذیر در همه پردازش‌های متنی است. در فارسی رسمی و به خصوص فارسی غیررسمی چنین مسئله‌ای می‌تواند به صورت جدی مشکل ساز شود. بخش عمده این خطاها بنابر دسته‌بندی کوکیک (۱۹۹۲) که خطاها را به سه دسته حروف چینی، شناختی و آوایی تقسیم کرده است، منشا آوایی و شناختی دارد. در این صورت اگر برای سایر مشکلات این بخش (چالش‌های پردازش فارسی) چاره‌جویی شود، بخش عمده این خطاها که آوایی و نگارشی است برطرف می‌شود. اما دسته دیگر خطاها یعنی خطاهای ناشی از حروف چینی نیز در بعضی موارد می‌تواند پردازش فارسی را دچار اختلال کند.

۲. پیشینه

آرمین و شمس‌فرد (۱۳۸۹) با استفاده از یک ریشه‌یاب رسمی (شریفلو و شمس‌فرد، ۲۰۰۸) و افزودن برخی تک‌واژه‌های تصریفی غیررسمی و تغییرات آوایی به آن، یک سیستم ریشه‌یابی برای فارسی غیررسمی طراحی کرده‌اند. روش کار آن به این صورت است که تک‌واژه‌های لیست شده را شناسایی و حذف می‌کند و تا جایی حذف تک‌واژه‌ها را ادامه می‌دهد که به ریشه معادل در واژگان رسمی و یا واژگان غیررسمی جمع‌آوری شده برسد. برای شناسایی ریشه کلمات هم از تعدادی قاعده تبدیل محاوره به رسمی استفاده می‌کند. در نهایت با استفاده از یک مدل زبان دوتایی^۲، کلماتی که در قاعده تصریفشان ابهام وجود دارد، اولویت‌بندی می‌کند. دقت گزارش شده برای این ریشه‌یاب ۹۳ درصد بر روی ۱۰۰ کلمه داده آزمون است.

علینقی‌زاده (۱۳۹۶) نیز با انجام پژوهشی مشابه آرمین و شمس‌فرد (۱۳۸۹) و اصلاح و افزودن قواعد بیشتری به آن موفق شده است دقت آن را ۶ درصد افزایش دهد.

اسدی (۲۰۰۷) و مرادی (۲۰۱۲) با بررسی پیکره‌های گفتاری فارسی، حذف و یا تغییر صداها را بررسی کرده‌اند. این تغییرات که در بیان و در میان سیلاب‌های کلمه اتفاق می‌افتد هنگام نگارش غیررسمی نیز معمولاً به حروف چینی منتقل می‌شود. هدف این مقاله شناسایی الگوهای تغییر آوایی و مدل کردن آنها جهت شناسایی و پوشش بیشتر کلمه‌های غیررسمی است.

۳. چارچوب پیشنهادی

قواعد تغییر آوایی و سایر تغییرات در حروف کلمات می‌تواند با استفاده از ساختار مبدل حالت متناهی^۳ پیاده شود. چنین ساختاری علاوه بر ایجاد امکان اعمال تغییرات آوایی و هم‌صدا، امکان پیاده‌سازی تغییرات بیانی و تا حدی املایی را نیز فراهم می‌کند. این قواعد صرفاً برای شناسایی به کار می‌رود و در مرحله تولید استفاده نمی‌شود.

¹ cognitive

² Bigram

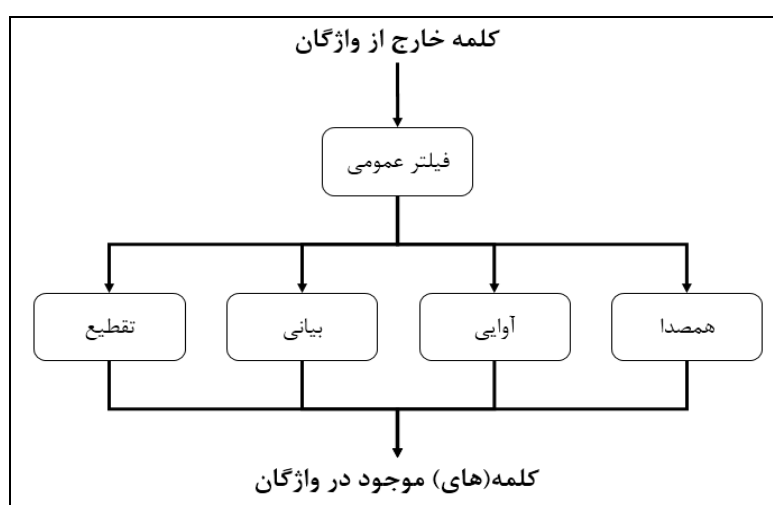
³ FST – Finite State Transducer

۱.۳. ابزار پیاده سازی

ابزار فوما^۱ (هولدن، ۲۰۰۹) یک ابزار متن آزاد و رایگان است که صورت‌بندی^۲ لکس^۳ و زبان قاعده‌پذیر^۴ فناوری زیراکس^۵ (بیسلی و کارتونن، ۲۰۰۳) برای ایجاد تغییر در مبدل‌ها و منطق مرتبه اول^۶ را پیاده کرده است. همین‌طور ابزار جستجوگر واژه / قاعده را در کنار سایر ابزارهای خود دارد. علاوه بر این کتابخانه‌هایی به زبان‌های سی، جاوا و پایتون جهت استفاده از مبدل‌ها و یا ایجاد تغییر در آنها در سطح برنامه‌نویسی برای ابزاری مستقل را فراهم کرده است. این ابزار امکان استفاده از چندین مبدل حالت متناهی^۷ را در کنار یکدیگر بوجود می‌آورد. بنابراین می‌توان به شکل جدا و یا در دنباله هم تعدادی مبدل استفاده کرد تا هر کدام تغییر خاصی را پوشش دهد.

۲.۳. ساختمان کلی

از آنجایی که فارسی امروزی (رسمی و غیررسمی) زوایای متفاوتی دارد، برای سهولت و مدیریت بر تحلیل کلمات آن می‌باید از چند مبدل متنوع استفاده کرد و تغییرات آوایی را جداگانه در قالب مبدل‌های مجزا استفاده کرد (شکل ۱).



شکل ۱ - ساختار کلی مبدل‌های استفاده شده در این پژوهش

۱.۲.۳. مبدل فیلتر عمومی

مرزنامه‌های فاصله، نیم‌فاصله و اتصال در این مبدل به صورت غیر قطعی^۸ می‌توانند جایگزین یکدیگر شوند. دلیل این کار پوشش همه حالت‌های فاصله دادن قطعات کلمه است که هم در فارسی رسمی و هم غیررسمی به صورت متنوع استفاده می‌شود. نویسه‌های ۱ و آ نیز به صورت غیر قطعی تعریف می‌شود. در نگارش کلمات دارای این دو حرف جایگزین شدن آنها با یکدیگر بسیار اتفاق می‌افتد. این جابجایی ممکن است در هر دو گونه رسمی و غیررسمی رخ دهد.

۲.۲.۳. مبدل همصدا

در این مبدل حروف همصدا جایگزین یکدیگر می‌شوند. در نگارش فارسی رسمی و غیررسمی به دلیل خطای شناختی و یا به عمد، این حروف می‌توانند جایگزین یکدیگر شوند (حروف همصدا در جدول ۱).

¹ Foma

² Formalism

³ lex

⁴ Regex – Regular Expression

⁵ Xerox

⁶ First Order Logic

⁷ Finite State Transducer - FST

⁸ Non-deterministic

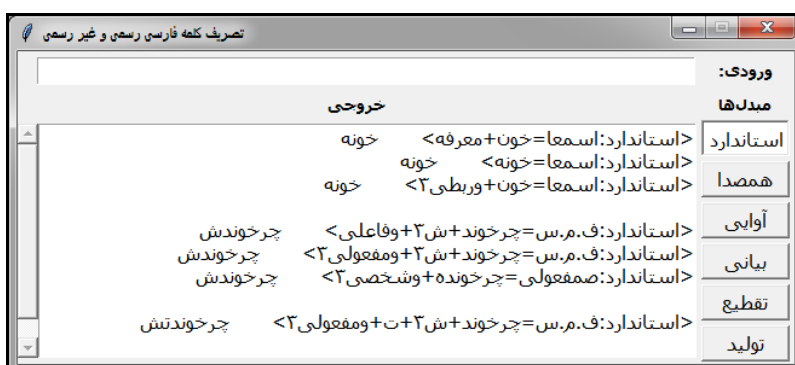
ظاهر می‌شود. در کلمه‌های تولید شده در خروجی، آن دو کلمه‌ای که مجموع طولشان مساوی طول کلمه اصلی است و به همان ترتیب، کلمه اصلی را می‌سازند، می‌توانند به عنوان جایگزین انتخاب شوند. برای مثال کلمه **ازمردم**، قطعه‌های شکل ۲ را تولید می‌کند. از این شش گروه تنها جفت کلمه(هایی) از بین آنها می‌تواند انتخاب شود که هر دو در واژگان موجود باشد.

ازمردم	ازمردم	ازمردم	ازمردم	ازمردم	ازمردم
--------	--------	--------	--------	--------	--------

شکل ۲ - قطعه‌های تولید شده از قطعه **ازمردم**

۳.۳. ابزار پیاده‌شده

برای پیاده‌سازی مبدل‌های تحلیل‌گر تصریفی همان‌طور که پیش‌تر ذکر شد از ابزار فوما استفاده شده است. ابزار پیاده‌شده این قسمت یک ابزار برای دسترسی آزمایشی به مبدل‌هاست که دارای یک واسط گرافیکی است و به صورت مستقل و تک به تک می‌توان کلمه را به تحلیل‌گر داد و مبدل مورد نیاز را انتخاب کرد و خروجی آن را دید. تصویر این واسط را در شکل ۳ مشاهده می‌کنید.



شکل ۳ - واسط کاربر (ابزار آزمایشگاهی) مبدل‌ها

مبدل استاندارد در این تصویر یک تحلیل‌گر تصریفی است که می‌تواند کلمات رسمی و غیررسمی فارسی را تحلیل کند. برای ارزیابی این مبدل‌ها آنها را در کنار این تحلیل‌گر قرار داده‌ایم و خروجی این مبدل‌ها به مبدل استاندارد متصل می‌شود تا تحلیل تصریفی کلمه خارج از واژگان شناسایی شده بدست آید.

۴. ارزیابی

در این ارزیابی از یک تحلیل‌گر تصریفی که قادر است کلمات رسمی و غیررسمی فارسی را تحلیل تصریفی کند استفاده شده است. کلماتی که در تحلیل‌گر شناسایی نشده است و یا به خطا شناسایی شده را به مبدل‌ها داده‌ایم و خروجی آنها را دوباره به تحلیل‌گر تصریفی انتقال دادیم و تغییر در خروجی را اندازه گرفته‌ایم. از آنجایی که بخشی از کلمات به کار رفته در زبان فارسی معاصر، کلمات رسمی است، علاوه بر نوع خطاها نوع کلمات از نظر رسمی بودن و غیررسمی بودن نیز بررسی شده است.

۴.۱. مجموعه داده

کلماتی که برای ارزیابی استفاده شده است از جملات زیرسیاق‌های زبان فارسی غیررسمی است؛ زیرسیاق‌های رسانه‌های اجتماعی، وبلاگ‌ها، زیرنویس فیلم، متن پیاده شده سخنرانی، مصاحبه، اجرای رادیو / تلویزیونی، نامه شخصی، شعر محاوره و نظر کاربران فضای مجازی در پایین مطالب و محصولات وبسایت‌های مختلف، برای این هدف جمع‌آوری شده است. دادگان جمع‌آوری شده از این زیرسیاق‌ها از نوع پیکره نمونه‌گیری^۱ شده است و نمونه‌های هر سیاق زبان فارسی غیررسمی به شکل

^۱ Sampling corpus

تصادفی^۱ انتخاب شده است (مکانری و هاردی، ۲۰۱۱). سعی شده است تا هم تنوع گونه و سیاق و هم نسبت متون حفظ شود و با این حساب خطای سوءگیری^۲ و خطای تصادفی^۳ کنترل و به حداقل برسد (بایبر، ۱۹۹۳-الف؛ بایبر، ۱۹۹۳-ب). بنابراین داشتن ویژگی توازن^۴ و ویژگی نمایندگی^۵ در جمع آوری آن رعایت شده است (مکانری و هاردی، ۲۰۱۱). مجموع کل دادگان حدود پنجاه هزار قطعه است و ۳۰ درصد آن تنها برای ارزیابی کنار گذاشته شده است. مجموع تعداد همه کلماتی که برای ارزیابی به شیوه بالا دوباره از میان داده‌های جمع‌آوری شده (۳۰ درصد ارزیابی) انتخاب شده است ۴۰۴۰ کلمه است که اگر کلمات یکتای آن را محاسبه کنیم ۱۷۸۶ کلمه می‌شود.

جدول ۳ - بررسی گونه‌ای خطاها

معیار	رسمی بودن	تحلیل‌گر تصریفی*	هم‌صدا	آوایی	بیانی	تقطیع
کمبود واژگان	غیررسمی	۴۰	۴۰	۲۸	۲۸	۲۸
	رسمی	۸۳	۸۳	۸۳	۸۳	۸۳
نقص در قاعده	غیررسمی	۴	۴	۴	۴	۴
	رسمی	۶	۶	۶	۶	۶
خطای هم‌صدا و کسره اضافه	غیررسمی	۳	صفر	۰	۰	۰
	رسمی	۰	۰	۰	۰	۰
به هم چسبیده	غیررسمی	۳	۳	۳	۳	صفر
	رسمی	۱	۱	۱	۱	۱
تغییر آوایی	غیررسمی	۵	۵	۳	۳	۳
	رسمی	۰	۰	۰	۰	۰
خطای املائی	غیررسمی	۸	۸	۸	۸	۸
	رسمی	۱۷	۱۷	۱۷	۱۷	۱۷
ادبی		۳	۳	۳	۳	۳
هشدار نادرست (FP)		۱۳	۱۳	۱۹	۱۹	۳۴
موفقیت (TP)	غیررسمی	۱۵۳۰	۱۵۳۳	۱۵۴۷	۱۵۴۷	۱۵۵۰
	رسمی	۲۱۷۴	۲۱۷۴	۲۱۷۴	۲۱۷۴	۲۱۷۴
از دست رفته (FN)	غیررسمی	۶۰	۵۷	۴۳	۴۳	۴۰
	رسمی	۱۱۲	۱۱۲	۱۱۲	۱۱۲	۱۱۲

* این یک تحلیل‌گر تصریفی با واژگان رسمی و غیررسمی محدود به خود است که در این ارزیابی در کنار مبدل‌های شناسایی کلمات خارج از واژگان استفاده شده است.

¹ Random sampling

² Bias error

³ Random error

⁴ Balanced

⁵ Representative

۱.۴. تحلیل نتایج

بررسی گونه‌ای مستقل از متن خطاهای کلمات (تایپ‌های) آزمون در جدول ۳ آمده است. کلمات یکتا کلماتی هستند که صرفاً از نظر نگارش کاملاً یکسانند و به کاربردهای متنوع احتمالی آنها از نظر صرفی-نحوی توجهی نمی‌شود. در مقابل تایپ‌های یک کلمه، به تمام کلمات یکتای یکسانی گفته می‌شود که از نظر صرفی-نحوی متفاوت از یکدیگر هستند (و هر کدام تحلیل تصریفی متفاوتی تولید می‌کند). همان‌طور که مشاهده می‌شود، در تحلیل‌گر تصریفی از مجموع ۱۰۷۸۶ کلمه یکتا، ۳۰۷۰۴ تایپ با موفقیت (TP) تولید شده است. ۱۷۲ تایپ را می‌بایست تولید می‌کرده اما از دست داده (FN) است و ۱۳ تایپ را هم به اشتباه (FP) تولید کرده است. سپس مرحله به مرحله (از راست به چپ) مبدل‌های این پژوهش برای شناسایی کلمات خارج از واژگان، بروی از دست‌رفته‌ها (FN) آزمایش شده و در صورتی که تغییری اتفاق افتاده در جدول مشخص شده است. در این جدول خط زیرین ساده زیر عدد نشانه بهتر شدن شاخص و خط زیرین منحنی زیر عدد نشان دهنده بدتر شدن شاخص نسبت به مبدل قبل‌تر از خود است.

کمتر از ۶۰ درصد تایپ‌ها، رسمی است. بیشتر خطاهای رخ داده در بین همه تایپ‌ها (۷۱.۵ درصد)، به دلیل کمبود واژگان است. رتبه دوم بیشترین از دست‌رفته‌ها، خطاهای املائی است (۲۵ مورد، ۱۴.۵ درصد همه خطاها)، که هیچ یک از مبدل‌ها قادر به رفع خطا و شناسایی آنها نیستند. خطاهای نقص در قاعده نیز با ۱۰ خطا در جایگاه بعدی است. این خطاها مربوط به تحلیل‌گر تصریفی است و مبدل‌های این پژوهش در بهبود آن نمی‌توانند نقش داشته باشند. خطاهای بعدی خطاهای آوایی است که مبدل آوایی موفق شده از این ۵ خطا ۳ مورد را شناسایی کند، همین‌طور کلمات خارج از واژگان غیررسمی نیز ۱۲ تایپ تولید کرده است که مبدل آوایی توانسته با موفقیت (TP) شناسایی کند (به این معنا که این کلمات صرفاً کلمات غیررسمی‌اند و می‌بایست در واژگان غیررسمی تحلیل‌گر وجود می‌داشتند). بیشتر کلمات به هم چسبیده نیز توسط مبدل تقطیع، شناسایی و تقطیع شده است. البته این مبدل در حین شناسایی هشدارهای نادرست (FP) نسبتاً زیادی نیز تولید می‌کند که دقت را کاهش می‌دهد. آخرین نوع خطاها هم استفاده از حروف هم‌صدا و استفاده از ه به جای کسره اضافه است که همگی آنها توسط مبدل هم‌صدا شناسایی و رفع شده است. از دست‌رفته‌های ادبی نیز ساختارهای ادبی‌ای است که تحلیل‌گر تصریفی و سایر مبدل‌ها قادر به شناسایی آنها نیست و مجموعاً سه خطا تولید کرده است که به مجموع از دست‌رفته‌های رسمی (۱۱۲) افزوده شده است.

معیارهای ارزیابی اصلی فراخوانی^۱، دقت^۲ و معیار اف (۱)^۳ تایپ‌های رسمی در ادامه آمده است. مبدل‌های شناسایی این پژوهش تأثیری در نتایج بدست آمده از تحلیل‌گر تصریفی برای تایپ‌های رسمی ندارد (جدول ۴). پایین آمدن معیار دقت نیز به دلیل کلی حساب کردن (بدون در نظر گرفتن رسمی یا غیررسمی بودن تایپ) هشدارهای غلط (FP) است.

جدول ۴ - ارزیابی تایپ‌های رسمی

معیار	تحلیل‌گر تصریفی	هم‌صدا	آوایی	بیانی	تقطیع
فراخوانی	٪۹۵.۱	٪۹۵.۱	٪۹۵.۱	٪۹۵.۱	٪۹۵.۱
دقت	٪۹۹.۴۱	٪۹۹.۴۱	٪۹۹.۱۳	٪۹۹.۱۳	٪۹۸.۴۶
معیار اف (۱)	٪۹۷.۲۱	٪۹۷.۲۱	٪۹۷.۰۷	٪۹۷.۰۷	٪۹۶.۷۵

فراخوانی تایپ‌های غیررسمی در مبدل هم‌صدا، آوایی و تقطیع بهبود می‌یابد اما دقت به دلیل افزایش هشدارهای خطا کاهش پیدا می‌کند (جدول ۵).

^۱ Recall

^۲ Precision

^۳ F-measure (1)

جدول ۵ - ارزیابی تایپ‌های غیررسمی

معیار	تحلیل‌گر تصریفی	هم‌صدا	آوایی	بیانی	تقطیع
فراخوانی	٪۹۶.۲۳	٪۹۶.۴۲	٪۹۷.۳	٪۹۷.۳	٪۹۷.۴۸
دقت	٪۹۹.۱۶	٪۹۹.۱۶	٪۹۸.۷۹	٪۹۸.۷۹	٪۹۷.۸۵
معیار اف (۱)	٪۹۷.۶۷	٪۹۷.۷۷	٪۹۸.۰۴	٪۹۸.۰۴	٪۹۷.۶۶

معیارهای ارزیابی اصلی فراخوانی، دقت و معیار اف (۱) برای تمامی کلمات مستقل از متن نیز در جدول ۶ آمده است.

۵. نتیجه‌گیری

همان‌طور که ملاحظه می‌شود تبدیل واحدهای خارج از واژگان به واحدهای درون واژگان در فراخوانی تایپ‌های رسمی تغییری ایجاد نمی‌کند. اما بیش از یک درصد (فراخوانی) به شناسایی تایپ‌های غیررسمی و در نتیجه کل تایپ‌ها کمک می‌کند. تغییر ایجاد نکردن در فراخوانی تایپ‌های رسمی به

جدول ۶ - ارزیابی کل تایپ‌ها

معیار	تحلیل‌گر تصریفی	هم‌صدا	آوایی	بیانی	تقطیع
فراخوانی	٪۹۵.۵۶	٪۹۵.۶۴	٪۹۶	٪۹۶	٪۹۶.۰۸
دقت	٪۹۹.۶۵	٪۹۹.۶۵	٪۹۹.۴۹	٪۹۹.۴۹	٪۹۹.۱
معیار اف (۱)	٪۹۷.۵۶	٪۹۷.۶	٪۹۷.۷۱	٪۹۷.۷۱	٪۹۷.۵۷

این دلیل است که این تغییرات آوایی به فارسی غیررسمی تعلق دارد و در فارسی رسمی کمتر رخ می‌دهد. از طرف دیگر شناسایی تغییرات آوایی گرچه مثبت‌های صحیح را افزایش می‌دهد اما هیچگاه تغییری در مثبت‌های غلط (FP) نمی‌تواند ایجاد کند. بنابراین انتظار بهبود این شاخص وجود ندارد و در بهترین حالت تنها می‌توان انتظار داشت شاخص تغییر نکند. همان‌طور که در جداول ارزیابی مشاهده می‌شود در مواردی شاخص دقت تغییر نکرده و در بعضی موارد شاخص بدتر شده است (مبدل آوایی و مخصوصاً مبدل تقطیع مثبت‌های غلط زیادی به رابطه دقت افزوده‌اند که باعث کاهش شاخص در این مبدل‌ها شده است).

جدا بودن هر مبدل و منحصر بودن محدوده قواعد آوایی هر یک می‌تواند استفاده از آنها را ساده سازد. بسته به نوع متن و بافتی که استفاده می‌شود و مبتنی بر سیاق می‌توان از مبدل متناسب بهره برد. به طور مثال برای متن‌های رسمی نیازی به استفاده از این مبدل‌ها نیست، در حالی که برای متن‌های غیررسمی استفاده از این مبدل‌ها می‌تواند مفید باشد. برای متن‌هایی که در آن از فاصله درست استفاده نشده و فاصله بین کلمات به درستی رعایت نشده است استفاده از مبدل تقطیع می‌تواند مفید باشد. تغییرات آوایی بین تک‌واژه‌های ترکیبی و سیلاب‌های کلمات نیز اتفاق می‌افتد. چنین قواعدی در این مقاله گنجانده نشده است اما برای پوشش بیشتر کلمات خارج از واژگان غیررسمی چنین قواعدی می‌تواند مفید باشد.

۶. فهرست منابع

آرمین، ن. و شمس‌فرد، م. (۱۳۸۹). «تبدیل متن محاوره‌ای فارسی به رسمی به کمک ان-گرام‌ها» در شانزدهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، دانشگاه صنعتی شریف.

علینقی‌زاده، ر.، دین‌محمدی، غ.، هراتی‌زاده، س. (۱۳۹۶). «تبدیل متن محاوره فارسی به متن رسمی فارسی در سطح تصریف و واژگان.» پایان‌نامه برای دریافت درجه کارشناسی ارشد در رشته زبان‌شناسی رایانشی در دانشکده علوم و فنون نوین، دانشگاه تهران.

- Assadi, Sh.. (2007). "Sound Deletion in Colloquial Persian." *SaarrbrÜcken*, 597-600
- Biber, D. (1993a). Using register-diversified corpora for general language studies. *Computational Linguistics*, 19(2), 219–241.
- Biber, D. (1993b). Representativeness in corpus design. *Literary and Linguistic Computing*, 8(4), 243–257.
- Hulden, M. (2009). *Finite-State Machine Construction Methods and Algorithms for Phonology and Morphology*. The University of Arizona.
- Hulden, M. (2009). "Foma: A Finite-State Compiler and Library". In *Proceedings of the 12th Conference of the European Chapter of the Association for Computational Linguistics: Demonstrations Session*, 29–32. Association for Computational Linguistics.
- McEnery, T., & Hardie, A. (2011). *Corpus linguistics: Method, theory and practice*. Cambridge University Press.
- Beesley, K R, and Karttunen, L. (2003). *Finite State Morphology (Xerox)*. CSLI Studies in Studies in Computational Linguistics. Stanford, Calif.
- Kukich, K. "Spelling Correction for the Telecommunications Network for the Deaf." *Communications of the ACM* 35, no. 5 (1992): 80–90.
- Moradi, H. (2012). "Sound Deletion in Colloquial Persian." In *Modern journal of applied linguistics*, 4 (3), p. 109-118.
- Sharifloo, A A, and Shamsfard, M. (2008). "A Bottom Up Approach to Persian Stemming." In *IJCNLP*, 583–88, 2008.