

Contemporary Persian Inflectional Analyzer

Davood Heidarpour

MSc in Computational Linguistics; Faculty of New Sciences and Technologies; University of Tehran; Tehran, Iran;
Email: d.heidarpour@ut.ac.ir

Elham S. Sebt

MSc in Computational Linguistics; Faculty of New Sciences and Technologies; University of Tehran; Tehran, Iran;
Email: e.sebt@ut.ac.ir

Mahmood Bijankhan

PhD in General Linguistics; Full Professor; Faculty of Literature and Humanities; University of Tehran; Tehran, Iran;
Email: mbjkh@ut.ac.ir

Mostafa Salehi*

PhD in Computer Engineering; Associate Professor;
Faculty of New Sciences and Technologies; University of Tehran;
Tehran, Iran Email: mostafa_salehi@ut.ac.ir

Hadi Veisi

PhD in Computer Engineering; Assistant Professor;
Faculty of New Sciences and Technologies; University of Tehran;
Tehran, Iran Email: h.veisi@ut.ac.ir

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. 36 | No. 4 | pp. 945-970

Summer 2021

<https://doi.org/10.52547/jipm.36.4.945>



Received: 19, Sep. 2019 Accepted: 07, Mar. 2021

Abstract: In recent years, the use of informal writing in Persian has grown significantly due to the increasing expansion of cyberspace and social media and platforms, and the tendency of users to bring the written language closer to colloquial speech. But on the other hand, proper tools to process this language register are not developed very much. One of the tools for low level processing of textual data is an inflectional analyzer. However, such tools are not developed for this register yet. Informal words have their own structures, stems, morphemes and clitics and they also make use of formal structures and units. Moreover, this register also consists of formal words so any analyzer for informal words should have the potential to analyze formal words, too. In this paper, it is tried to cover all inflectional structures of informal Persian language to build an inflectional analyzer. A corpus of most of its known sub-registers is constructed to extract words, morphemes and inflectional rules and morphotactics. A part of this corpus is used for testing the analyzer. After extracting 1786 unique words of the test part, inflectional analyzer f-measure is equal to 97.67%.

* Corresponding Author

This tool can be used in computational processing of Persian language and it can also be used in teaching Persian, specifically colloquial Persian to non-Persian learners.

Keywords: Computational Linguistics, Inflectional Analyzer, Informal Persian Register, Contemporary Persian, FST, Persian Teaching

تحلیلگر تصریفی فارسی معاصر

داود حیدرپور

کارشناسی ارشد زبان‌شناسی رایانشی؛ دانشکده علوم
و فنون نوین؛ دانشگاه تهران؛ تهران، ایران؛
d.heidarpour@ut.ac.ir

الهام سادات سبط

کارشناسی ارشد زبان‌شناسی رایانشی؛ دانشکده علوم
و فنون نوین؛ دانشگاه تهران؛ تهران، ایران؛
e.sebt@ut.ac.ir

محمود بی‌جن‌خان

دکتری زبان‌شناسی؛ استاد تمام؛ گروه زبان‌شناسی؛
دانشگاه تهران؛ تهران، ایران
mbjkhan@ut.ac.ir

مصطفی صالحی

دکتری مهندسی کامپیوتر؛ دانشیار؛ دانشکده علوم
و فنون نوین؛ دانشگاه تهران؛ تهران، ایران؛
mostafa_salehi@ut.ac.ir

هدای ویسی

دکتری مهندسی کامپیوتر؛ استادیار؛ دانشکده علوم
و فنون نوین؛ دانشگاه تهران؛ تهران، ایران؛
h.veisi@ut.ac.ir



مقاله برای اصلاح به مدت ۴ ماه نزد پدیدآوران بوده است.

دربافت: ۱۳۹۸/۰۶/۲۸ | پذیرش: ۱۳۹۹/۱۲/۱۷

چکیده: در سال‌های اخیر، کاربرد گونه نوشتاری غیررسمی زبان فارسی به دلیل گسترش روزافزون فضای مجازی و شبکه‌های اجتماعی و تمایل کاربران به نزدیک کردن زبان نوشتار به گفتار رشد چشمگیری داشته است. با وجود این، ابزارهای پردازش این گونه زبانی به میزان لازم توسعه داده نشده است. تحلیلگرهای تصریفی از جمله ابزارهایی است که در پردازش زبانی کاربرد وسیعی دارد و تاکنون برای گونه غیررسمی طراحی و پیاده‌سازی نشده است. با توجه به این که گونه نوشتاری غیررسمی در کنار واژگان و قواعد صرفی و نحوی مختص به خود، در بخشی از واژه‌ها و ساختارها با گونه رسمی مشترک است، در این پژوهش با پوشش فارسی رسمی و غیررسمی اولین ابزار تحلیل تصریفی فارسی معاصر برای همه اقسام واژه توسعه داده شده و تلاش شده همه ساختارهای تصریفی واژه‌های فارسی غیررسمی پوشش داده شود. این ابزار به صورت قاعده‌مند و مستقل از بافت و با بهره‌گیری از مبدل حالت محدود، پی‌بست‌ها و وندهای تصریفی رسمی و غیررسمی را در واژه‌های زبان‌شناسایی و تحلیل کرده، ستاک‌های رسمی و غیررسمی را نیز استخراج می‌کند. به منظور پوشش دادن تمام ساختهای و حالت‌های تصریفی، با توجه به

نشریه علمی | رتبه بین‌المللی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایران‌دک)

شای (چاپی) ۲۲۰۱-۸۲۲۳
شای (انگلیسی) ۲۲۰۱-۸۲۲۱

نمایه در SCOPUS، ISC، و IISTA
jipm.irandoc.ac.ir

دوره ۳۶ | شماره ۴ | صص ۹۴۵-۹۷۰
تایپستان ۱۴۰۰

<https://doi.org/10.52547/jipm.36.4.945>



رویکرد مستقل از بافت، الگوریتم برای هر واژه، تمام خوانش‌ها و معانی گوناگونی را که می‌تواند بسته به قرارگیری در بافت‌های گوناگون داشته باشد، تحلیل و ارائه می‌کند. به‌منظور استخراج و بررسی واژگان و قواعد تصريفی و نگارشی گونهٔ غیررسمی، پیکرهٔ فارسی معاصر از سیاق‌ها و زیرسیاق‌های گوناگون این گونهٔ زبانی تهیه شده و در طراحی و آزمون تحلیلگر مورد استفاده قرار گرفت. آزمون تحلیلگر با استفاده از ۱۷۸۶ واژه یکتاپ استخراج شده از پیکره، نتیجه ۹۶/۶۷ درصد را در معیار اف به دست داده است. از این ابزار می‌توان در انواع تحلیل‌ها و کاربردهای پردازش رایانه‌ای زبان فارسی و همچنین در آموزش فارسی، به‌ویژه محاورهٔ فارسی به‌غیر فارسی زبان استفاده کرد.

کلیدواژه‌ها: پردازش زبانی، تحلیلگر تصريفی، گونهٔ غیررسمی فارسی، فارسی معاصر، مبدل حالت محدود، آموزش فارسی

۱. مقدمه

گونه‌ای از زبان فارسی که به عنوان زبان رسمی کشور در اسناد و مکتوبات حکومتی، آموزشی، علمی و نیز روزنامه‌ها و نشریات به کار می‌رود، گونهٔ نوشتاری معیار یا رسمی است. در کنار این گونه می‌توان به گونهٔ غیررسمی اشاره کرد که به عنوان نوشتار ارتباطی در شبکه‌های اجتماعی، پیام‌رسان‌های تلفنی، وبلاگ‌ها و گاهی سایت‌ها و نامه‌های الکترونیکی استفاده می‌شود و کاربر تلاش می‌کند زبان نوشتار را هرچه بیشتر به گونهٔ گفتاری نزدیک کند. هرچند این گونهٔ نوشتاری، ساختاری مختص به خود دارد و از لحاظ صرفی، نحوی و واژگانی با زبان نوشتاری معیار متفاوت است، اما در کنار تفاوت‌ها و جوهر اشتراک دو گونه نیز بالاست. در بررسی آماری پیکره‌ای که برای این پژوهش جمع‌آوری شده (شامل بیش از ۴۹ هزار واژه که به صورت دستی تقطیع^۱ شده)، ۵/۸۳ درصد (بیش از ۴۱ هزار) واژه‌های متون فارسی غیررسمی با زبان فارسی گونهٔ رسمی مشترک است و تنها ۱۶/۵ درصد واژه‌ها غیررسمی است (بخش ۳). لازم به ذکر است که واژه غیررسمی بر اساس این پژوهش، واژه‌ای است که حداقل یک عنصر غیررسمی در ساختار خود داشته باشد و این عنصر ریشه یا هر یک از اجزای تصريفی واژه است.

در حوزهٔ پردازش رایانه‌ای زبان، تحلیل صرفی به عنوان پردازش پایه در بسیاری از پردازش‌های زبانی سطح بالاتر کاربرد دارد، اما ابزارهای شناسایی فارسی غیررسمی برخلاف گسترش بسیار این گونهٔ زبانی در رسانه‌های اجتماعی و فضای وب، توسعهٔ بسیار

1. tokenize

اند کی یافته‌اند.

پژوهش‌های انجام‌شده در حوزه ساخت‌واثر زبان فارسی بیشتر به گونه رسمی زبان پرداخته‌اند، از جمله، «اسلامی» و همکاران (۱۳۸۳)، «اسلامی و علی‌زاده لجمیری» (۱۳۸۸)، Shamsfard, Jafari and Ilbeygi (2010) و «مواجحی، اسلامی و وزیرنژاد» (۱۳۹۰). تحلیلگرهای تصریفی که در این پژوهش‌ها پیاده‌سازی شده، مختص زبان فارسی رسمی است و قادر به تصریف فارسی غیررسمی نیست. این پژوهش‌ها بر اساس ساختار تصریفی ارائه‌شده توسط «اسلامی» و همکاران (۱۳۸۳) طراحی شده‌اند. تنها پژوهش Megerdoomian (2000) بر اساس ساختار تصریفی‌ای که خود او استخراج و تبیین کرده، پیاده‌سازی شده است. تعداد اندکی از پژوهش‌ها نیز به فارسی غیررسمی پرداخته‌اند. «مگردویان» به صورت پراکنده ساختارهای غیررسمی را شناسایی کرده است (Megerdoomian 2008). این ساختارها می‌بایست به تحلیلگر رسمی او - ساختارهایی که خود او استخراج و تبیین کرده - افزوده می‌شد تا تحلیلگر تصریفی بتواند در کنار تصریف واژگان رسمی، واژگان غیررسمی را نیز پوشش دهد، اما این طرح ناتمام باقی مانده است. گرچه این پژوهش قبل از فرآگیر شدن پیام‌رسان‌ها و شبکه‌های اجتماعی انجام شده، اما با توجه به رشد وبلاگ‌های فارسی و گسترش کاربرد فارسی غیررسمی در آن اولین پژوهشی است که به فارسی غیررسمی در فضای مجازی پرداخته است. «تازه‌جانی و بحرانی» با انجام پژوهشی محدود، تنها بخش کوچکی از افعال غیررسمی را پوشش داده و تحلیلگری تصریفی برای آن ساخته‌اند (۱۳۹۲). «طیب‌زاده» نیز مانند «مگردویان» با مطالعه‌ای پیکربندیاد، اما برخلاف آن محدود به داستان‌ها و نمایشنامه‌های صد سال اخیر فارسی، رخدادهای کلمات غیررسمی را بررسی کرده و ساختار مشاهده‌شده در کلمات را گزارش کرده است (۱۳۹۸). این پژوهش صرفاً نظری است و فاقد ابزار تحلیل رایانه‌ای این گونه کلمات است.

استفاده از زبان غیررسمی در اینترنت در میان سخنوران سایر زبان‌ها نیز رایج بوده و تلاش برای تحلیل رایانه‌ای آن نیز در جریان است. برای مثال، Torjmen and Haddar (2018) برای تحلیل گونه بیانی تونسی و Alshargi and Rambow (2016) برای تحلیل گونه بیانی یمنی (صنایی) و مراکشی، که همگی متفاوت از عربی استاندارد مدرن (Ryding 2005) یا عربی نوشتاری مدرن^۱ (Badawi, Carter and Gully 2013) هستند، با شناسایی

1. Modern Written Arabic (MWA)

ساختار چنین کلماتی (با استخراج از پیکرهایی که برای این منظور ساخته‌اند) و افزودن آن‌ها به ساختار مبدل‌های^۱ عربی استاندارد یا نوشتاری مدرن، تحلیلگرهای تصrifی برای گونه‌های بیانی خود طراحی کرده‌اند.

با توجه به کاستی‌های این حوزه، در پژوهش حاضر تلاش شده است که ساختارهای تصrifی فارسی غیررسمی به‌طور کامل بررسی و شناسایی شده، و تحلیلگر تصrifی فارسی غیررسمی بر مبنای قواعد جامع و مانع در این حوزه طراحی و پیاده‌سازی شود. هدف در طراحی این تحلیلگر شناسایی و تحلیل ستاک، وندهای تصrifی و بی‌بست‌های واژه است که در سامانه‌های پردازش زبان طبیعی^۲ کاربرد دارد.

از آنجا که در گونه‌غیررسمی از گونه‌رسمی نیز استفاده می‌شود، بنابراین، هر تحلیلگر واژه برای فارسی غیررسمی می‌بایست قادر به تحلیل واژه‌های فارسی رسمی هم باشد. فارسی‌ای که در این پژوهش مد نظر است، فارسی امروزین است که در نوشتار و گفتار فارسی زبانان در گونه‌رسمی و غیررسمی استفاده می‌شود و شامل گونه‌ادبی و تاریخی نمی‌شود. بنا بر نظر «لازار»^۳ فارسی معاصر کاربرد امروزین فارسی را در هر شکلش در نظر دارد و نه ساختاری که لزوماً در متون کلاسیک فارسی وجود دارد و یا تعریف شده است (Lazard 1992).

۲. چارچوب پیشنهادی

رویکرد رایج در تحلیل زبانی قاعدة‌مند و در سطح واژه، استفاده از مبدل حالت محدود^۴ است که می‌تواند دو رشته را به یکی‌گر نگاشت کند. این نگاشت بین واژه و تمام قطعات سازنده قاعدة کلی واژه صورت می‌گیرد. بنابراین، ورودی مبدل می‌تواند واژه و خروجی آن قاعدة سازنده واژه باشد. به‌منظور پیاده‌سازی یک تحلیلگر با استفاده از مبدل حالت محدود به سه منبع زبانی نیاز داریم: واژگان، قواعد تصrifی و قواعد نگارشی (Jurafsky and Martin 2008).

واژگان^۵ فهرستی از ستاک‌ها و وندهای زبان همراه با اطلاعاتی مثل مقوله دستوری واژه است. قواعد همنشینی^۶ تک‌واژه‌ها، مدلی از همنشینی و باهم‌آیی تک‌واژه در یک واژه

1. transducer

2. نظری تحلیل معنایی، نظر کاوی، بازناسانی گفتار و غیره.

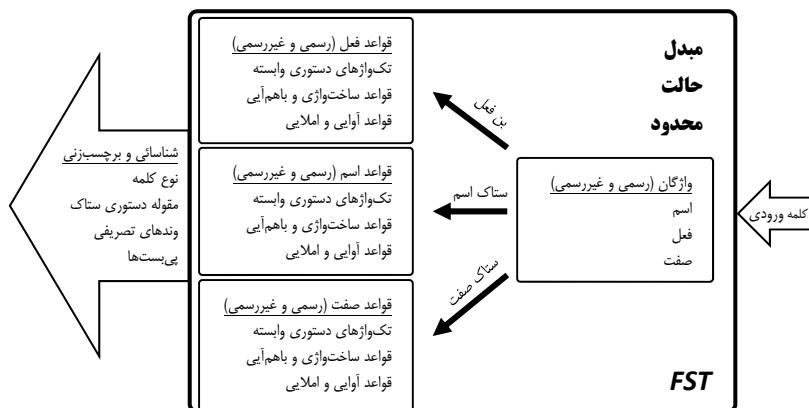
3. finite state transducer (FST)

4. lexicon

5. morphotactic rules

ارائه می‌کند و قواعد املایی، تغییرات املایی ناشی از تغییرات واژه-واجی^۱ را هنگام ترکیب دو تکه‌واژه توصیف می‌کند.

در این پژوهش به منظور پردازش تصریفی قاعده‌مند از ابزار «فوما»^۲ (Hulden 2009)، که یک ابزار مبدل حالت محدود متن آزاد و رایگان است، استفاده شده است. «فوما» این امکان را فراهم می‌آورد که با قرار دادن چندین مبدل در سیستم، واژه ورودی را از یکی یا از همه آن‌ها عبور داد و قاعده تولید کرد. هر مبدل می‌تواند برای تغییر و یا شناسایی بخشی از قواعد ساخت‌واژه به کار رود. همچنین، کاربر می‌تواند با استفاده از کتابخانه‌های تعریف شده یا به صورت شخصی شده در مبدل‌ها جست‌وجو انجام دهد و یا ترتیب و نحوه اجرا شدن مبدل‌ها را شخصی‌سازی کند. شکل ۱، ساختار مفهومی یک مبدل را نشان می‌دهد. کلمه ورودی پس از شناسایی ستاک و ساختار تصریفی و برچسبزنی همه اجزای سازنده آن در خروجی نمایش داده می‌شود.



شکل ۱. مدل مفهومی مبدل حالت محدود تحلیلگر تصریفی

۱-۲. چالش‌های پیاده‌سازی تحلیلگر تصریفی فارسی معاصر

چنان‌که ذکر شد، گونه‌ای از زبان که به عنوان فارسی معاصر در این پژوهش مورد توجه است، گونه‌ای ارتباطی است که به شکل گسترده در شبکه‌های اجتماعی، پیام‌رسان‌ها و وبلاگ‌ها مورد استفاده قرار می‌گیرد و دارای ویژگی‌های ارتباطی نزدیک

به گفتار است. با توجه به محدودیت‌های فنی رسانه^۱ نوشتاری فارسی و فقدان استاندارد، کاربران از شیوه‌های گوناگونی برای نگارش استفاده می‌کنند. اما به رغم تغییرات آوایی و یکدست نبودن قوانین نگارشی، فارسی غیررسمی در بسیاری از موارد در ساختار تصrifی خود از قواعدی تعیت می‌کند که در معدود پژوهش‌های این حوزه به برخی از آن‌ها اشاره شده است. اما لازم است برای تحلیل دقیق و درست، با بررسی داده‌های استاندارد این گونه زبانی، ساختار جامع و مانعی برای آن تعریف شود. با توجه به در دسترس نبودن داده استاندارد برای این گونه نوشتاری، نخستین قدم فراهم آوردن داده مناسب به‌منظور بررسی و استخراج الگوهای نوشتاری، تک‌واژه‌ای تغییریافته و قواعد ساخت‌واژی است. با توجه به این که در این گونه نوشتاری به‌طور معمول واژه‌ها چه در شکل رسمی و چه در شکل غیررسمی، تابع الگوی نگارشی یکسان و ثابتی نیستند و پوشش و ذخیره همه این واژه‌ها در پیاده‌سازی تحلیلگر امکان‌پذیر نیست، بنابراین، بخشی از واژه‌ها، به‌ویژه آن‌هایی که تحت تأثیر تغییرات آوایی قرار می‌گیرند، تبدیل به واژه‌های خارج از واژگان تحلیلگر می‌شوند و شناسایی آن‌ها به‌راحتی امکان‌پذیر نیست. برای به حداقل رساندن تأثیر چنین مواردی در دقت نهایی تحلیلگر لازم است به نکات زیر توجه شود:

- ◊ حذف برخی حروف: همزه در پایان واژه‌ها یا بر روی پایه‌های «و»، «آ»، و «ی» وجودی غیر قطعی دارد و ممکن است حذف شود؛ مثلاً «أعضاء»: «اعضا». حرف «ه» در نقش واکه در صورتی که در پایان یک تک‌واژه قرار بگیرد، در بسیاری از موارد، در هنگام اتصال به تک‌واژی دیگر حذف می‌شود؛ مثلاً «به‌طوریکه»: «بطوریکه»، همه شون: همشون».
- ◊ فاصله‌گذاری: فاصله، نیم‌فاصله و اتصال، سه حالت در کنار هم قرار گرفتن واژه‌ها و یا اجزای واژه‌های است. گرچه «فرهنگستان زبان و ادب فارسی» استانداردی برای آن در نظر گرفته (صادقی و زندی مقدم ۱۳۸۵)، اما به‌طور معمول، در نگارش فارسی رعایت نمی‌شود؛ مثل «کتاب‌ها، کتابها و کتاب‌ها» و در نگارش غیررسمی نیز تنوع بیشتری تولید می‌کند.
- ◊ خطای املایی: خطای املایی یکی از مشکلات اجتناب‌ناپذیر در همه پردازش‌های متنی به‌ویژه فارسی غیررسمی است. بخشی از این خطاهای که منشا نگرشی دارد، با

برطرف کردن سایر چالش‌های پردازش فارسی غیررسمی قابل کنترل است؛ مانند جایگزینی حروف هم‌صدا با یکدیگر. سایر خطاهای ناشی از حروف چینی نیز با روش‌های شناسایی و رفع خطای املایی می‌باشد برطرف شود.

۳. دادگان

در تهیه دادگان برای این پژوهش تلاش شد تمام زیرسیاق‌های فارسی غیررسمی شناسایی شده، برای هر کدام متونی تهیه، بررسی و برچسب گذاری شود. مجموعه پیکره جمع آوری شده نزدیک به پنجاه هزار واژه است. واژگان این پیکره به شکل دستی تقطیع شده و حدود ۳۰ درصد آن برای ارزیابی کنار گذاشته شد. از بقیه برای بررسی ساخت‌های تصریفی، آمارگیری از میزان توزیع ساخت‌های مختلف، بررسی و استخراج واژگان و ساخت‌های غیررسمی استفاده شد. تمام واژه‌های غیررسمی این پیکره به شکل دستی معادل‌نویسی شده و بن‌واژه^۱ آن‌ها نیز استخراج شده است. ساختار پیکره‌ای که به طور متوازن از این زیرسیاق‌ها (که همگی مربوط به زبان فارسی غیررسمی است) استفاده می‌کند، از نوع پیکره نمونه‌گیری شده^۲ است. برای هر سیاق^۳ زبان فارسی غیررسمی نمونه‌ها، هم در مرحله جمع آوری اولیه و هم در مرحله گرینش به شکل تصادفی^۴ انتخاب شده است (McEnry and Hardie 2011). حجم داده هر بخش هم به نسبت کاربرد آن زیرسیاق انتخاب شده است. جدول ۱، داده‌های جمع آوری شده در تهیه پیکره فارسی معاصر را به تفکیک سیاق‌ها و زیرسیاق‌ها نشان می‌دهد.

۴. قواعد و واژگان فعلی

در این بخش واژگان فعلی تحلیلگر که شامل بن افعال و تک‌واژه‌ای وابسته متصل به فعل است و همچنین، ساخت تصریفی افعال در گونه غیررسمی توضیح داده می‌شود.

1. lemma

2. sampling corpus

3. register

4. random sampling

جدول ۱. سیاق‌ها و زیرسیاق‌های موجود در پیکرهٔ فارسی معاصر

ردیف	سیاق	زیرسیاق و حجم کلی
۱	گفت‌و‌گو و بیان واقعی ^۱	مصطفی، سخترانی از پیش آماده شده، اجرای رادیو/تلوزیونی از روی متن؛ ۱۲۴۸ واژه
۲	گفت‌و‌گو و بیان خیالی ^۲	رمان، نمایشنامه، فیلم‌نامه، زیرنویس فیلم، شعر محاوره؛ ۷۵۶۷ واژه
۳	نظر کاربران فضای مجازی	صرف کننده کالا یا خدمات، مقالات خبری و متفرقه؛ ۹۰۵۰ واژه
۴	پیام‌رسان تلفنی	مکالمه شخصی، مکالمه گروهی، اطلاع‌رسانی؛ ۱۱۹۴۲ واژه
۵	شبکه اجتماعی	پست‌ها، پاسخ‌ها؛ ۸۴۳۱ واژه
۶	وبلاگ	پست‌ها، پاسخ‌ها؛ ۸۹۰۳ واژه
۷	نامه شخصی و خاطرات روزانه	۲۱۴۶ واژه

۴-۱. واژگان فعلی

در ساختمان فعل‌های رسمی ساده و پیشوندی از بن‌های فعل ماضی و مضارع استفاده می‌شود. بن‌های رسمی از واژگان «زایا» (اسلامی و همکاران ۱۳۸۳)، «ویراستیار» (کاشفی، نصری و کعانی ۱۳۸۹)، واژگان «پرلکس» (Sagot and Walther 2010)، و پیکرهٔ جمع آوری شدهٔ فارسی غیررسمی به دست آمده است. بن فعل‌های حال و گذشتهٔ غیررسمی نیز از پیکرهٔ جمع آوری شده و هم با معادل‌سازی بن فعل‌های رسمی به دست آمده است که در مجموع، شامل ۵۱۶ بن ماضی ساده رسمی و ۸۷ بن غیررسمی، ۴۹ بن ماضی پیشوندی رسمی و ۲۳ بن غیررسمی، ۳۷۹ بن مضارع ساده رسمی و ۸۷ بن غیررسمی و نیز ۴۹ بن مضارع پیشوندی رسمی و ۲۲ بن غیررسمی است. شناسه‌ها و پی‌بست‌ها با توجه به پژوهش‌های انجام‌شده، مانند (2008) «اسلامی» و همکاران (۱۳۸۳)، «انوری و گیوی» (۱۳۹۱)، «بی‌جن‌خان» (۱۳۸۶) و از پیکرهٔ جمع آوری شده به دست آمده است (جدول ۲).

در ساخت افعال گونهٔ غیررسمی استفاده از پی‌بست‌های فاعلی و مفعولی رایج است. پی‌بست‌های مفعولی «م، ت، ش، مان، تان، شان» در متون رسمی نیز به ندرت استفاده می‌شود، اما در متون غیررسمی صیغه‌های جمع بیشتر به صورت «مون، تون، شون» استفاده می‌شود. پی‌بست فاعلی «ش» مختص گونهٔ محاوره است و در فعل‌های سوم شخص به کار

می‌رود. بیشتر نمودهای فعل ماضی مانند ماضی ساده، استمراری و بعيد، صرف نظر از گذرا یا ناگذر بودن فعل پی‌بست فاعلی را می‌پذیرند. پی‌بست فاعلی می‌تواند به فعل‌های مضارع اخباری و التزامی لازم نیز افزوده شود.

جدول ۲. شناسه‌های فارسی رسمی و غیررسمی^۱

شخص و شمار	بعد از همخوان‌ها و واکه‌ی			بعد از واکه‌ی آ	بعد از واکه‌ی و
	رسمی	غ.رسمی	رسمی	غ.رسمی	رسمی
۱. امفرد	(ای)م	م!	(ای)م	(ای)م	م!
	می‌رویم	میام	می‌آیم	می‌زیم، می‌گم	می‌خندم، می‌زیم، می‌گم
۲. امفرد	(ای)ای	ای!	(ای)ای	ای!	ای!
	می‌رویی	میای	می‌آیی	می‌زیی، می‌گی	می‌خندی، می‌زیی، می‌گی
۳. امفرد	(ای)اه	ا!	(ای)اد	مضارع: ا!	مضارع: ا!
	می‌روید	میاد	می‌آید	ماضی: Ø	ماضی: Ø
				می‌خندد، زیست	می‌گه، می‌ذاشت
۱. جمع	(ای)یم	یم!	(ای)یم	(ای)یم	یم!
	می‌رویم	میایم	می‌آیم	می‌زیم، می‌گیم	می‌خندیم، می‌زیم، می‌گیم
۲. جمع	(ای)ین	ید!	(ای)ین	ید!	ید!
	می‌روید	میاین	می‌آید	می‌زیید	می‌گین
		میایین، میاید			
۳. جمع	(ای)ند	ان!	(ای)ند	ان!	اند!
	می‌رویند	میان	می‌آیند	می‌گن	می‌خندند

(۱). او مدش و بچه‌ها رو به صفت کرد، بعد شم بر دشون بیرون.

(۲). بچه‌های ما همش سراغ دختر کوچولوتونو می‌گیرن، فردا که می‌ایین با خودتون بیارینش.

(۳). خودش گفت می‌خواسته ماجرا رو بگه ولی او نداشتند.

افزون بر پی‌بست‌های فاعلی و مفعولی پی‌بست‌های «و»، «م» نیز که صورت کوتاه‌شده حرف عطف «و» و حرف ربط «هم» است و نیز پی‌بست تأکید «ها» می‌تواند به ساخت افعال گونه‌ی غیررسمی اضافه شوند (Megerdoomian 2008؛ شفاقی ۱۳۹۴) که در توزیع تکمیلی یکدیگر هستند.

(۴). فایده نداشت اگه می‌گفتیم گوش نمی‌کرد.

۱. ا. بدون هیچ فاصله‌ای به تک واژ قبیل متصل می‌شود. ×: با نیم فاصله به تک واژ قبیل متصل می‌شود.

(۵). اونم رفتو با یه مامور برگشت.

همچنین، در نوشتار گونه غیررسمی از پی‌بست تأکیدی «ا» نیز استفاده می‌شود که با بررسی پیکره جمع آوری شده شناسایی و استخراج شد.

(۶). اگه حرف گوش نکنی نمی‌برمتا!

۴- ساخت تصريف فعلی

به منظور طراحی و پیاده‌سازی تحلیلگر تصريفی فارسی معاصر قواعد مربوط به ساخت تصريفی افعال گونه رسمی از منابع و پژوهش‌های انجام شده در این حوزه از جمله از «اسلامی» و همکاران (۱۳۸۳) و «انوری و گیوی» (۱۳۹۱) استخراج شد و مورد استفاده قرار گرفت. ساخت تصريفی فعل‌ها در گونه غیررسمی نیز از الگوی ساخت فعل در گونه رسمی تبعیت می‌کند، با این تفاوت که افعال غیررسمی امکان پذیرش طیف گسترده‌تری از پی‌بست‌ها را دارند که به عنوان قواعد افزوده به تحلیلگر ساخت‌واژی معرفی شده است. در ساخت فعل غیررسمی حداقل یک عنصر غیررسمی باید وجود داشته باشد که عبارت است از: بن غیررسمی فعل، شناسه غیررسمی، پی‌بست مفعولی، پی‌بست فاعلی، تک‌واژه‌ای محاوره (جدول ۶). به عنوان مثال، فعل «گفتیشان» گرچه از بن رسمی «گفت»، شناسه رسمی «ی» و پی‌بست ضمیری رسمی «شان» تشکیل شده است، اما دارای ساختی غیررسمی است؛ زیرا فعل‌های رسمی پی‌بست مفعولی نمی‌پذیرند (Megerdoomian 2000، 2008). فعل «رفتش» نیز که از بن رسمی و شناسه سوم شخص مفرد (\emptyset) تشکیل شده، به این دلیل که پی‌بست فاعلی «ش» پذیرفته است، یک فعل غیررسمی به حساب می‌آید (اسلامی و علی‌زاده لجمیری ۱۳۸۸). در این پژوهش با بررسی تحقیقی که به صورت ناتمام در این زمینه توسط Megerdoomian (2008) انجام شده، همین‌طور، منابع مشترک با فعل رسمی و دیگری پیکره جمع آوری شده، الگوی تصريفی افعال غیررسمی مطابق شکل ۲، استخراج و مورد استفاده قرار گرفت.

$$\text{ساختمان فعل رسمی} + \left[\begin{array}{l} \text{(پی‌بست مفعولی)} \\ \text{(پی‌بست فاعلی)} \end{array} \right] + \text{(اجزای ساختمان غیررسمی)}$$

شکل ۲. تصريف افعال غیررسمی

فعل‌های گذرا می‌توانند پی‌بست مفعولی و یا پی‌بست فاعلی پذیرند. در مقابل، فعل‌های ناگذرا تنها می‌توانند پی‌بست فاعلی پذیرند. در فعل‌های گذرا پذیرفتن پی‌بست فاعلی یا پی‌بست مفعولی سوم شخص مفرد هر دو منجر به افزوده شدن «ش» به انتهای بن فعل می‌شود که ابهام ایجاد می‌کند.

۴-۲-۱. موارد استثنای در ساخت فعل امر

در چارچوب قاعدة تصریفی فعل امر غیررسمی می‌توان چند مورد استثنای شناسایی و معرفی کرد:

- ◊ در ساخت فعل‌های غیررسمی این امکان وجود دارد که بن‌های رسمی یا غیررسمی با شناسه‌های رسمی یا غیررسمی ترکیب شوند؛ به عنوان مثال: «بگذرانید، بگذرانین، بگذرونید، بگذرونین». در ساخت فعل امر مفرد در صورتی که بن مضارع مختوم به واکه (رو، گو، شو، ده) باشد، از بن غیررسمی استفاده نمی‌شود.
- (۷) مصدر گفتن-بن رسمی: گو «بگویید»، بن غیررسمی: گ (بگید) ساخت امر مفرد: «بگو»
- ◊ مصدر پیشوندی «وایسادن» نیز برای ساخت امری مفرد و جمع دو بن واژه متفاوت دارد، با این تفاوت که هر دو بن واژه آن غیررسمی است. امر مفرد: «وایسا»، امر جمع: «وایسید».
- ◊ از بن مضارع گریستان (گری) فعل امر مفرد ساخته نمی‌شود و در حالت امر صرف‌اً از فعل مرکب استفاده می‌شود؛ به عنوان مثال: «گریه کن»

۴-۲-۲. فعل‌های ناقص

برخی بن فعل‌های غیررسمی مانند فعل‌های ناقص که همه ساخت‌ها و زمان‌هایشان متداول نیست (انوری و گیوی ۱۳۹۱)، در همه ساخت‌ها استفاده نمی‌شود و در صورتی می‌تواند در ساخت فعل مورد استفاده قرار گیرد که همراه با پیشوندهای تصریفی (می، ن) باشد، در غیر این صورت، از بن رسمی استفاده می‌شود. فعل‌های پیشوندی که با این بن‌ها ساخته می‌شوند نیز الگویی مشابه دارند (جدول ۳).

جدول ۳. فعل‌های ناقص ساخت‌های ماضی

بن ناقص فعل ماضی	ذاشت (گذاشت)	شوند ^۱ (نشاند)	شست (نشست)	واذاشت (واگذاشت)	فروشنست (فروشنشت)
ساخت مجاز ساده منفی	نشاشتم	نشوندی	نششم	وانداشت	فرونششت
استمراری	(ن) میداشتم	(ن) میشوندی	(ن) میشتم	وا(ن) میداشت	فرو(ن) میشست
نقلی مستمر	(ن) میداشته	(ن) میشونده	(ن) میشته	وا(ن) میداشته	فرو(ن) میشته
نقلی بعید	نشاشته	نشونده	نشسته	وانداشته	فرونشسته
الترامی-منفی					
ساخت	ذاشتم*	شوندی*	شیشم*	واذاشتُم*	فروشنست*
غيرمجاز	ذاشته*	شونده*	شیشه*	واذاشته*	فروشنسته*
الترامی-مثبت					

۴-۲-۳. اتصال پی‌بست‌های ضمیری فعل مختوم به واکه

«مگردو میان» تغییرات آوایی و نگارشی را هنگام اتصال پی‌بست‌های ضمیری به افعال غیررسمی مضارع اخباری و ماضی نقلی سوم شخص مفرد بررسی کرده است (Megerdoomian 2008). با توجه به این که این افعال به واکه («از لحظه نگارشی») ختم می‌شوند، در هنگام تلفظ، واکه به همخوان «ت» تبدیل می‌شود. این تغییر آوایی در صورت نگارشی، با جایگزینی «ه» با «ت» و یا درج «ت» در واژه نمایش داده می‌شود. همه بچه‌ها رو صحیح و سالم با اتوبوس برد و او^ر دشون / او^ر ده^ه تشون.

۵. قواعد و واژگان غیر فعلی

در این بخش به واژگان غیر فعلی تحلیلگر، شامل ستاک‌های غیر فعلی و وندهای تصريفی و پی‌بست‌های متصل به آنها پرداخته و قواعد تصريفی آن بررسی می‌شود.

۵-۱. واژگان

واژگان در این بخش شامل ستاک‌های غیر فعلی، وندهای تصريفی و پی‌بست‌های رسمي و غیررسمی است که می‌توانند به هر ستاک متصل شوند. ستاک‌ها بر اساس دستور زبان فارسی «انسوری و گیوی» (۱۳۹۱) دسته‌بندی و مقولات واژگانی اسم، قید،

۱. با توجه به داده‌های پیکره برای بن «نشاند» دو تک واژگونه غیررسمی «نشوند» و «شوند» شناسایی و به تحلیلگر معرفی شده است.

عدد، حرف ربط، حرف اضافه، شاخص، ضمیر (مشترک، شخصی)، ضمیر/ صفت (اشارة، مبهم، پرسشی، تعجبی) متمایز شده‌اند. در بخش ضمیر/ صفت در صورتی که ستاک به تنها‌یی استفاده شود، صفت و یا ضمیر است (مستقل از بافت قابل تشخیص نیست) و در غیر این صورت، ضمیر است. این نکته نیز قابل ذکر است که برچسب‌دهی به مقولات واژگانی مستقل از بافت تعریف شده است. جدول ۵، تعداد ستاک‌هایی را که ذیل هر مقوله واژگانی برای تحلیلگر تعریف شده، نشان می‌دهد.

مانند بخش افعال، در این بخش نیز در صورتی که واژه ساختار یا حداقل یک عنصر غیررسمی داشته باشد، به عنوان واژه غیررسمی شناسایی و پردازش می‌شود؛ به عنوان مثال: «کتاب»، «جعبه‌مون». همچنین، برای تمام اسمی، اطلاعاتی در مورد مفرد یا جمع بودن هر اسم، به عنوان مثال اسمی جمع مکسر عربی و نیز وندهای جمعی که هر اسم می‌تواند پذیرد، مثلاً «آن، ها» برای اسمی جاندار، وارد شده است.

جدول ۴. مقولات واژگانی غیر فعلی تعریف شده برای تحلیلگر تصویری

مقوله واژگانی	اسم	اسم خاص	قید	صفت	عدد
تعداد رسمی	۲۷۹۴۰	۶۲۴۲	۱۳۷۴	۱۶۶۵۰	۴۸
غیررسمی	۸۰	۱۸	۲۲۷	۴۰	۱۷
مقوله واژگانی	۷۷	۲۹	۱۰	۳۰۲	۱۶۴
تعداد رسمی	۲۲	۳	۳	۲۶	۴
غیررسمی					

۱-۱-۵. تک واژه‌های جمع

در زبان فارسی اسم‌ها با وندهای تصویری «ها»، «آن» و «گان (تک واژگونه آن)» جمع بسته می‌شود. افزون بر آن، وندهای جمع عربی مانند «ین، ون، ات (جات)» در زبان فارسی رایج و مورد استفاده است. در ساختار غیررسمی نیز افزون بر وندهای فوق، از «ا» به تنها‌یی استفاده می‌شود.

(۹). سلام دوستان! طرح‌ای جدیدمون آماده‌م.

۵-۱-۲. تکوازهای نکره / موصول، کسره اضافه و معرفه‌ساز

جدول ۵. الگوهای نگارشی تکوازهای نکره / موصول، کسره اضافه و معرفه‌ساز

ستاک	مختوم به واکه‌ی مخصوص به همخوان	مختوم به واکه‌ی الف / واو	مختوم به واکه‌ی ۵	تکوازه کسره اضافه
-	-	ای / ۰	ای / برده، برده‌ی	بدگوی، هیولا
تکوازه نکره	ای / ائی / اعی	ای / ائی / ای	ای / دوگانگی ای، پرده‌ای، خنده‌ای، گربه‌ی	کتابی، کلوبنی، طلاعی، (یه) جوراعی، ایتالیاعی
تکوازه معرفه‌ساز	اه	انه / آنه	انه / عه	کتابه، آب‌نمانه (عه)، تابلوه (عه)

تکوازه معرفه‌ساز «ه» با اتصال به پایه اسم یا صفت جایگزین اسم، آن را شناسه می‌کند و منحصر به گونه غیررسمی است. جدول ۶، الگوهای نگارشی را برای تکوازهای نکره / موصول، کسره اضافه و معرفه‌ساز در گونه غیررسمی، با توجه به بافت حرفی که در آن قرار می‌گیرند، نشان می‌دهد.

۵-۱-۳. پی‌بست‌های ربطی

این پی‌بست ساخت اسنادی را به اسم‌ها و غالب اقسام دیگر واژه که در این بخش آمده، اضافه می‌کند. جدول ۶، الگوهای مختلف نگارشی را در بافت حرفی نشان می‌دهد.

جدول ۶. پی‌بست‌های ربطی^۱

ش.ش.	رسمی‌بودن	همخوان	واکه او	واکه ه	واکه الف	واکه ی
مفرد ۱، ۲، ۳	رسمی	س! (م، ی)، س! (م، ی)	س! (ام، ای)، س! (ام، ای)	س (ام، ای)، س (ام، ای)	س (ام، ای)، س (ام، ای)	س [ام، ای]، س [ام، ای]
غیررسمی		مریضم، مریضی، مریضه	بدگوام، بدگوم، بدگواه، بدگونه،	بردهم، بردهی، هیولاام، بالام، نظامیام، بالاس	س اس، س اس، س اس، س اس، س اس	س ای، س ای، س ای، س ای، س ای
جمع ۱، ۲، ۳	رسمی	س! (یم، ید)، س! (یم، ید)، ند)	س (ایم، اید)، س (ایم، اید)، ند)	س (ایم، اید)، س (ایم، اید)	س (ایم، این)، س (ایم، این)	س [ایم، اید]، س [ایم، اید]
غیررسمی		مریضیم، مریضین، مریضن	تنهایم، تنهاید، تنهایان، تنهایان، تنهایان، تنهایان، تنهایان، تنهایان	پرروایم، پررواید، پرروایان، پررواین، پررواند، پررونن، پردون	س [اید، این]، س [اید، این]، س [اید، بین]، س [اید، بین]، س [اند، ن]، س [اند، ن]	س [ایم، این]، س [ایم، این]، س [ایم، این]

۴-۱-۵. پی‌بست‌های ضمیری (شخصی)

این پی‌بست‌ها می‌توانند در نقش ملکی یا مفعولی ظاهر شوند و نیز با اتصال به جزء غیرفعالی فعل مرکب نقش مطابق مفعولی یا فاعلی را به عهده گیرند (شقاقی ۱۳۹۴). از آنجا که این تمایز بیشتر در سطح واژه و تصریف قابل تمیز نیست، همه آن‌ها در بخش واژه‌های غیرفعالی با عنوان پی‌بست‌های ضمیری (شخصی) نام‌گذاری شده‌اند.

۱. الگوهای نگارشی متفاوت برای یک تک واژه داخل کروشه آورده شده است.

جدول ۷. پی‌بست‌های ضمیری

شخص شمار رسمی‌بودن	ستاک مختوم به همخوان	ستاک مختوم به واکه او-	ستاک مختوم به واکه د	ستاک مختوم به واکه ای
۱،۲،۳ فرد	رسمی کتابم	س! (م، ت، ش) س! (م، ت، ش)	س! (ام، ات، اش) س! (ام، ات، اش)	س! (ام، ات، ش) س! (ام، ات، ش)
۱،۲،۳ جمع	غ.رسمی کتابشون	س! (ام، ت، ش) س! (ام، ت، ش) لبوش، کارفرمات جمعهم	س! (ام، ت، ش) س! (ام، ت، ش) لبوشان، لبوتون، جبهه‌تان، جبهه‌شون کتیرا‌تان، کتیرا‌شون	س! (ام، تان، شان) س! (ام، تان، شان) س! (امون، تون، شون) س! (امون، تون، شون) س! (امون، تون، شون) لبوشان، لبوتون، جبهه‌تان، جبهه‌شون کتیرا‌تان، کتیرا‌شون
۱۰	رسمی کتابها	س! (ها) س! (ها)	س! (ها) س! (ها)	س! (ها) س! (ها)

۵-۱. سایر تک‌واژه‌ای وابسته مختص گونه غیررسمی

«شقاقی» پی‌بست‌های ساده زبان فارسی را که صورت کوتاه‌شده تک‌واژه‌ای مستقل «را، و، هم» است و بیشتر در محاوره و گفتار سریع و خودمانی به کار می‌رود، معرفی می‌کند (۱۳۹۴). این پی‌بست‌ها در گونه نوشتاری غیررسمی نیز مطابق جدول ۸ به عنوان آخرین تک‌واژه به ساختار واژه افزوده می‌شود. افزون بر موارد ذکر شده، با توجه به بررسی داده‌ها در گونه غیررسمی، پی‌بست‌های تأکیدی «ها، ا» که «شقاقی» تنها قابل اتصال به گروه فعلی می‌داند، می‌تواند به مقوله‌های غیرفعلی نیز افزوده شوند که در واژگان غیرفعلی تحلیلگر تعریف شده است.

(۱۰). آدم خیلی تبلی بود، تبلایا، باورت نمیشه!، دست به سیاه سفید نمی‌زد.

جدول ۸. برخی تک‌واژه‌ای وابسته مختص گونه غیررسمی^۱

ستاک مختوم به ...	ستاک ها (تائید)	۱ (تائید)	و (اعطف)	دو (دوا)	و (دوا)	ستاک هم (دوا+هه)	رم (دوا+هه)
همخوان	س! (ها) کتابها	س! (ها) کتابها	س! (رو) کتابرو	س! (او) کتابو	س! (رو) کتابرو	س! (ام) کتابم	-
واکه واو	س! (ها) لبوها	س! (ها) لبوها	س! (رو) لبورو	س! (او) لبوو	س! (رو) لبورو	س! (ام) کتابم	-
واکه ای	س! (ها) نظامیها	س! (ها) نظامیها	س! (رو) نظامیرو	س! (او) نظامیو	س! (رو) نظامیرو	س! (ام) نظامیم	-

۱. س: ستاک

ستاک معتوم به ...	ها (تائید)	۱ (تائید)	و (اعطف)	رو (رو)	و (رو)	رم (دا+هم)	نم (هم)
واکه الف کتابها	-	س اها کتابها	س او کتاباو	س او کتابارو	س او کتابارو	س ارم کتابارم	س ارم کتابارم
واکه ه پنهانها	-	س ×ها پنهانها	س ×و پنهو	س ×و پنهو	س ×و پنهو	س ارم پنهارم	-

۲-۵. قواعد غیر فعلی

ساختر تصریفی مقوله‌های واژگانی یا به عبارتی نوع و ترتیب پیوستن وندهای تصریفی و پی‌بست‌ها به ستاک‌های غیر فعلی در گونه‌رسمی زبان با توجه به پژوهش‌های پیشین، از جمله «اسلامی» و همکاران (۱۳۸۳) و «انوری و گیوی» (۱۳۹۱) تعیین شده و در تحلیلگر مورد استفاده قرار گرفته است. برای گونه‌غیررسمی نیز تلاش شد با توجه به پیکره جمع آوری شده و سایر پژوهش‌های این حوزه از جمله Megerdoomian (2008) برای هر یک از مقوله‌های واژگانی قواعد جامع و مانع به گونه‌ای تعریف شود که هم تمام ساخت‌های ممکن برای هر مقوله را شامل شود و هم از تولید ساخت‌های نادرست و زاید جلوگیری کند. این قواعد به طور خلاصه در جدول‌های ۹ و ۱۰ آورده شده است. جدول ۹، ترتیب و امکان باهم‌آیی را برای وندها و پی‌بست‌های گوناگون نشان می‌دهد که در ۹ گروه تعریف شده است. جدول ۱۰، ساخت‌های ممکن برای هر مقوله واژگانی را با استفاده از گروه‌های تک‌واژی معرفی شده در جدول ۹، توصیف می‌کند. در هر دو جدول تک‌واژ یا تک‌واژه‌ایی که داخل پرانتز قرار گرفته‌اند، اختیاری‌اند و امکان حذف از ساختار واژه را دارند. در جدول ۹، تک‌واژ یا تک‌واژه‌ایی که نسبت به هم در توزیع تکمیلی هستند، در ردیف‌های مجزا، تعریف شده و در جدول ۱۰ با نشانه «//» از هم جدا شده‌اند. به عنوان مثال، جدول ۱۰ در مقوله «حرف اضافه» نشان می‌دهد که پی‌بست ضمیری می‌تواند به حرف اضافه متصل شود و بعد از آن پی‌بست ربطی و تأکیدی (ساخت ۲) قرار گیرد؛ «حواست بهشونه‌ها». همچنین، این امکان وجود دارد که بعد از پی‌بست ضمیری، پی‌بست کوتاه‌شده «هم: م» قرار گیرد که با پی‌بست ربطی و تأکیدی در توزیع تکمیلی است؛ «حواست بهشون (بهشون هم) باشه». همین طور در «تو خودت جیره خورشونی!» اسم بعد از همراه شدن با ساختار پی‌بست ضمیری (شون) با یک پی‌بست ربطی دوم شخص مفرد (ی) همراه می‌شود (جدول ۹، شماره ۹).

جدول ۹. الگوهای باهم‌آبی و ندهای تصریفی و پی‌بست‌ها در گونه غیررسمی

شماره	باهم‌آبی تک‌واژها	شماره	باهم‌آبی تک‌واژها
۱	را + (تاكيد)	۲	(ربطي) + (تاكيد)
۳	(را) + (هم)*	۴	نكره + (ربطي)
۵	را + (هم)* تاكيد	۶	ضميري + را (ربطي)
۷	تکواز عالی ساز تکواز تفضیلی ساز	۸	موصولی + را (ربطي) ... + که (هم) + را (ربطي)
۹	(جمع)		$\left(\begin{array}{l} (ربطي) + (تاكيد) \\ (هم)* + را \\ نكره + (ربطي) \\ (هم) + (ربطي) + (ضميري) + موصولی \\ (ربطي) + (هم) + (هم) + (ربطي) + (هم) \\ را + (تاكيد) + (هم) \\ عطف \\ اضافه \\ معرفه + (رابطه) + (هم)* + (هم) \end{array} \right)$

جدول ۱۰. الگوهای باهم‌آبی وندهای تصریفی و بی‌بست‌ها در ساختار مقوله‌های واژگانی غیرفلی در گونهٔ غیررسمی

مقوله واژگانی ساختار	مقوله واژگانی ساختار	شخصی
اسم + ۹	شخصی + (۸/۵/۲ / عطف / اضافه)	اسم
صفت + ۹ + ۷	(۴/۶ + جمع + پرسش)	صفت
عدد + تا + (جمع)	(۲/۳/۴ + ضمیری + ۱/۲ / هم)	عدد
عدد + (ترتیبی ۱ + (ترتیبی ۲) + (جمع))	(۵/۲ / عطف / اضافه)	مبهم
مشترک + (ضمیری) + (منفی) + (پیشوند) + (منفی) + بن ماضی + ن	(۱/۲ / هم / عطف) مصدر	مشترک
حرف اضافه حرف اضافه + (ضمیری) + (۲/۲ / هم)	صفت مفعولی (پیشوند) + (منفی) + صفت مفعولی + ۹	حرف اضافه
۹ + اشاره ^۱		اشاره ^۱

۶. ارزیابی

به منظور ارزیابی تحلیلگر تصریفی فارسی معاصر، از حدود ۳۰ درصد پیکرهٔ فارسی معاصر که در بخش ۳، توضیح داده شد، استفاده شده است. به این منظور، جملاتی از هر سیاق زبان فارسی غیررسمی به صورت تصادفی به گونه‌ای انتخاب شد که نسبت تنوع گونه و سیاق در آن‌ها حفظ شود و خطای سوگیری و خطای تصادفی کنترل شده به حداقل برسد (Biber 1993a/1993b). با توجه به این که تحلیل واژه‌ها در تحلیلگر، مستقل از بافت انجام می‌شود، نخست، واژه‌های جملات به صورت دستی جداسازی و استخراج شده، ۱۷۸۶ واژهٔ یکتای به دست آمده برای آزمون تحلیلگر مورد استفاده قرار گرفت. در ارزیابی رویکرد مستقل از بافت، توانایی تحلیلگر در تولید درست تمام قواعد ممکن برای هر واژه سنجیده می‌شود. هر یک از این قواعد تعریف کنندهٔ تایپ^۲ خاصی از واژه است که در بافت مخصوص به خود معنا پیدا کرده و استفاده می‌شود. هر تایپ قاعدهٔ سازندهٔ مختص به خود دارد. به طور مثال، برچسب‌هایی که در پیکرهٔ متنی زبان فارسی (Bijankhan et. Al. 2011) استفاده شده، مختص به قاعدهٔ سازندهٔ تایپ (آن کلمه در بافتی خاص است، اما قاعده‌های) سازنده‌ای که تحلیلگر در خروجی خود تولید می‌کند، مربوط به تمام بافت‌هایی است که کلمه می‌تواند در آن‌ها ظاهر شده و به نسبت آن

۱. اشاره شامل ساختار (کسره) اضافه و معرفه نمی‌شود.

2. type

معانی مختلف داشته باشد. به عبارت دیگر، تمام تایپ‌های کلمه پوشش داده می‌شود. جدول ۱۱، خروجی تحلیلگر را برای ورودی «مردم» نشان می‌دهد. تمام تایپ‌های ممکن این ورودی در بافت‌های مختلف در میان خروجی آن قرار دارد. از میان خروجی‌ها تایپ اول و سوم غیررسمی و بقیه رسمی‌اند.

جدول ۱۱. نمونه خروجی تحلیلگر تصویری برای ورودی «مردم»

ورودی خروجی	مثال تایپ در بافت	برچسب اجزای سخن تایپ
مردم <ف.م.س=مردم+ش۳+هم>	اگه مردم (مردم هم) جوابشو نده.	فعل ماضی ساده
<ف.م.س=مردم+ش۱+رسمی>	اگه مردم (من مردم) سر خاکم بیا.	فعل ماضی ساده
< اسم عام مردم (مردم هم) مردی قدیم.>	اسم عام	
< اسم عام مردم (مردم من) غیریه.>	اسم عام	
< اسم عام=مردم+وربطی۱+رسمی>	صدام نشون میده که مردم (مردم هستم). اسم عام	
< اسم عام=مردم+رسمی>	مردم جمع شده بودن.	اسم عام

در این رویکرد، مثبت‌های درست^۱ قاعده‌هایی هستند که توسط تحلیلگر به درستی تولید شده‌اند. مثبت‌های اشتباه^۲ قاعده‌هایی هستند که به اشتباه تولید شده و منفی اشتباه^۳ قاعده‌هایی هستند که می‌بایست توسط تحلیلگر تولید می‌شده، اما تولید نشده‌اند. فراخوانی^۴ نشان‌دهنده میزان قاعده‌های درست شناخته شده برای قطعات است و از تقسیم TP بر جمع TP و FN به دست می‌آید. صحبت^۵ نشان‌دهنده میزان درست بودن قواعدی است که توسط تحلیلگر تولید شده‌اند و از تقسیم TP بر جمع TP و FP به دست می‌آید. معیار اف^۶ نیز از ترکیب دو معیار فراخوانی و صحبت به شکل متوازن به دست می‌آید، به طوری که می‌توان میزان تأثیر هر یک از دو معیار را مشخص کرد. رابطه (۱) توزیع مساوی (۵۰ درصد-۵۰ درصد) هر دو معیار را به دست می‌دهد.

$$\text{معیار اف} = \frac{\text{درستی} \times \text{فراخوانی}}{\text{درستی} + \text{فراخوانی}} \quad (1)$$

جدول ۱۲، نتایج ارزیابی تحلیلگر را با استفاده از سه معیار فراخوانی، صحبت و معیار اف برای واژه‌های رسمی و غیررسمی آزمون نشان می‌دهد.

1. true positive (TP)

2. false positive (FP)

3. false negative (FN)

4. recall

5. precision

6. f-measure

جدول ۱۲. نتایج ارزیابی تحلیلگر برای گونه رسمی، غیررسمی و مجموع هر دو گونه

گونه زبانی	معابر (مجموع)	فراخوانی	صحت	معیار اف
رسمی	۹۵/۵۶	۹۵/۱	۹۹/۴۱	۹۷/۲۱
غیررسمی	۹۶/۲۳	۹۶/۲۳	۹۹/۱۶	۹۷/۶۷
معابر (مجموع)	۹۵/۵۶	۹۵/۱	۹۹/۶۵	۹۷/۵۶

تحلیلگر تصریفی برای مجموع ۱۷۸۶ واژه یکتای آزمون، ۳۷۰۴ قاعده یا تایپ را با موفقیت (TP) تولید کرده و همین طور، ۱۷۲ قاعده را می‌بایست تولید می‌کرده، اما از دست داده (FN) است و ۱۳ قاعده را هم به‌اشتباه (FP) تولید کرده است.

جدول ۱۳، بررسی موردی خطای FN را به تفکیک برای دو گونه رسمی و غیررسمی نشان می‌دهد. همان‌طور که مشاهده می‌شود، کمبود واژگان با وزن ۷۱/۵ درصد، مؤثرترین عامل در رخداد خطای FN در بین همه تایپ‌هاست. رتبه‌های بعدی شامل خطای املایی (۲۵ مورد، ۱۴/۵ درصد کل عوامل) و نقص در قاعده (۱۰ مورد، ۵/۸ درصد) است.

جدول ۱۳. بررسی خطای FN برای هر دو گونه زبانی رسمی و غیررسمی

گونه زبانی	خطای هم‌صدا	خطای هم‌ضاده	نقص در قاعده	به هم‌چسبیده	تفییر آوازی	خطای املایی	کمبود واژگان	نقص در قاعده	و کسره اضافه
رسمی	۸۳	۶	۰	۱	۰	۱۷	۰	۰	۱
غیررسمی	۴۰	۴	۳	۵	۳	۸	۴۰	۳	۵

به علت نمونه‌گیری تصادفی در جمع‌آوری پیکره و داده آزمون، نسبت واژه‌های رسمی آزمون به واژه‌های غیررسمی در حدود ۶۰ به ۴۰ است. از طرف دیگر، دایره واژه‌های رسمی گسترده‌تر از واژه‌های غیررسمی است و این منجر به تولید واژه‌های خارج از واژگان بیشتر رسمی نسبت به گونه غیررسمی می‌شود (طبق جدول ۱۳، دو برابر؛ ۸۳ به ۴۰). واژه‌های خارج از واژگان فراخوانی تایپ‌های رسمی را بیش از غیررسمی کاهش داده است. از طرف دیگر، ساختهای ساده‌تر رسمی صحت تایپ‌های رسمی را نسبت به غیررسمی افزایش داده است.

در این پژوهش جداسازی واژه‌های آزمون به صورت دستی انجام شده است. پیش‌بینی می‌شود اگر این جداسازی به شکل خودکار انجام شود، فراخوانی را به‌ویژه برای واژه‌های غیررسمی کاهش دهد.

۷. نتیجه‌گیری

تحلیلگر تصریفی پایین ترین سطح پردازش را (بعد از جداساز) بر روی متن فارسی انجام می‌دهد و اطلاعات تصریفی را به قطعه‌های متن خام اضافه می‌کند. اطلاعات به دست آمده از تحلیلگر تصریفی را می‌توان در سطوح بالاتر تحلیل نحوی و شناسایی گروههای نحوی استفاده کرد. با توجه به این که واژه‌های رسمی بخش قابل توجهی از واژه‌های فارسی امروز را تشکیل می‌دهد، تحلیل تصریفی این واژه‌ها نیز در کنار واژه‌های فارسی غیررسمی بخشی از فرایند پردازشی در تحلیلگر تصریفی فارسی معاصر است. برای تحلیل تصریفی همه این نوع واژگان فارسی از مبدل حالت محدود استفاده شده است. به دلیل رویکرد مستقل از بافت تحلیلگر، برای هر واژه تمام تحلیل‌ها و قواعد احتمالی مربوط به خوانش و تحلیل معنایی، وابسته به بافت‌های گوناگون ارائه می‌شود. با افزودن یک مدل آماری برچسب‌زن صرفی-نحوی^۱ می‌توان این ابزار را به یک تحلیلگر تصریفی مبتنی بر بافت تبدیل کرد. در مرحلهٔ شناسایی قاعدهٔ دقیق از یین قاعده‌های تولیدی برای هر واژه، جدا از روش‌های آماری و مبتنی بر بافت، می‌توان از اطلاعات افزوده‌ای که در تصریف غیررسمی نسبت به تصریف رسمی وجود دارد، کمک گرفت. وندها و واژه‌بسته‌ای که امکان اتصال به ستاک در ساختار غیررسمی را دارند، به دلیل تنوع بالاتر در بردارندهٔ اطلاعات صرفی-نحوی بیشتری هستند که می‌تواند در تجزیه و تحلیل نحوی و معنایی مورد استفاده قرار گیرد. همچنین، خروجی این تحلیلگر به گونه‌ای طراحی شده است که بتوان ابزارهای مکمل و ساده‌ای مانند ریشه‌یاب و ابزار تقطیع ساخت‌وآزاد بر اساس آن ساخت تا در تحلیل زبانی به کار آید. از جمله کاربردهای دیگر این ابزار می‌توان به آموزش فارسی به غیرفارسی زبانان اشاره کرد. با توجه به پوشش فارسی غیررسمی، آموزش ساختار تصریفی کلمات گفتار به زبان آموزان فارسی و تمرين و تکرار آن با این ابزار توسط زبان آموز امکان‌پذیر است.

بر اساس جدول ۱۲، بیشترین منفی‌های اشتباه در فارسی رسمی و در فارسی غیررسمی مربوط به کمبود واژگان است. با افزودن واژگان مناسب تا اندازه قابل توجهی فراخوانی تحلیلگر افزایش خواهد یافت. بعد از نقص کمبود واژگان بیشترین تعداد منفی اشتباه مربوط به خطاهای املائی است. در صورت استفاده از یک خطایاب و اصلاح‌کنندهٔ خطای املائی در کنار تحلیلگر تصریفی، فراخوانی به‌ویژه برای گونهٔ رسمی افزایش خواهد یافت.

1. morpho-syntactic part-of-speech tagger

فهرست منابع

- اسلامی، محرم، مسعود آتشگاه، صدیقه علیزاده لمجیری، و طاهره زندی. ۱۳۸۳. واژگان زیایی زبان فارسی. اولین کارگاه پژوهشی زبان فارسی و رایانه. تهران.
- اسلامی، محرم، و صدیقه علیزاده لمجیری. ۱۳۸۸. ساختار تصریفی کلمه در زبان فارسی. زبان و ادب فارسی. نشریه دانشکده ادبیات و علوم انسانی دانشگاه تبریز: ۲۱۱-۱۸.
- انوری، حسن، و حسن گیوی. ۱۳۹۱. دستور زبان فارسی. ویرایش چهارم. تهران: انتشارات فاطمی.
- بی جن خان، محمود. ۱۳۸۶. پیاده‌سازی استاندارد ایگلز در پیکره متون زبان فارسی معاصر. مطالعه و تحقیق جهت تدوین پژوهشنامه عملیاتی دادگان. تهران: دبیرخانه شورای عالی اطلاع‌رسانی.
- تازه‌جانی، سمیه، و محمد بحرانی. ۱۳۹۲. بررسی روند تغییرات در تبدیل فرم رسمی افعال به فرم محاوره‌ای و ارائه یک تحلیلگر صرفی برای افعال محاوره‌ای. اولین هم‌اندیشی زبان فارسی و اینترنت. تهران.
- حیدرپور، داود، مصطفی مصالحی، محمود بی جن خان، هادی ویسی، و حمید رنجبر. ۱۳۹۸. شناسایی و پوشش واحد‌های خارج از واژگان در فارسی غیررسمی. پنجمین همایش ملی زبان‌شناسی رایانشی. انجمن زبان‌شناسی ایران، تهران.
- شقاقی، ویدا. ۱۳۹۴. وند گروهی. زبان و زبان‌شناسی. مجله انجمن زبان‌شناسی ایران، پژوهشگاه علوم انسانی و مطالعات فرهنگی ۹ (۱۷): ۲۶-۲۶.
- صادقی، علی اشرف، و زهرا زندی مقدم. ۱۳۸۵. فرهنگ املایی زبان فارسی. تهران: فرهنگستان زبان و ادب فارسی.
- طبیزاده، امید. ۱۳۹۸. مبانی و دستور خط فارسی شکسته. تهران: پژوهشگاه علوم انسانی و مطالعات فرهنگی کاشفی، امید، میترانصری، و کامیار کعناعی. ۱۳۸۹. خطایابی املایی خودکار در زبان فارسی. تهران: دبیرخانه شورای عالی اطلاع‌رسانی.
- مواجی، حمید، محرم اسلامی، و بهرام وزیرنژاد. ۱۳۹۰. پارس مورف: تحلیلگر صرفی زبان فارسی. پردیش علائم و داده‌ها ۸ (۱): ۸-۸.

References

- Alshargi, Faisal, and Owen Rambow. 2016. Morphologically Annotated Corpora and Morphological Analyzers for Moroccan and Sanaani Yemeni Arabic. In 10th Language Resources and Evaluation Conference (LREC 2016). Portoroz.
- Badawi, El Said, Michael Carter, and Adrian Gully. 2013. *Modern Written Arabic: A Comprehensive Grammar*. London: Routledge.
- Biber, Douglas. 1993a. Representativeness in Corpus Design. *Literary and Linguistic Computing* 8 (4): 57-243.
- Biber, Douglas. 1993b. Using Register-Diversified Corpora for General Language Studies. *Computational Linguistics* 19 (2): 41-219.

- Bijankhan, Mahmood, Javad Sheykhzadegan, Mohammad Bahrani, and Masood Ghayoomi. 2011. Lessons from building a Persian written corpus: Peykare. *Language Resources and Evaluation* 45 (2): 143–164.
- Ferguson, Charles A. 1959. Diglossia. *Word* 15 (2): 325–340.
- Hulden, Mans. 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. Athens.
- Jurafsky, Daniel, and James H Martin. 2008. *Speech and Language Processing*. 2nd Edition. New Jersey: Prentice Hall.
- Lazard, G. 1992. *A grammar of contemporary Persian*. Costa Mesa, CA: Mazda Publishers.
- McEnery, Tony, and Andrew Hardie. 2011. *Corpus Linguistics: Method, Theory and Practice*. Cambridge: Cambridge University Press.
- Megerdoomian, Karine. 2008. *Analysis of Farsi Weblogs*. Washington DC: MITRE Corporation., ______. 2000. *Persian Computational Morphology: A Unification-Based Approach*. New Mexico: Computing Research Laboratory, New Mexico State University.
- Ryding, Karin C. 2005. *A Reference Grammar of Modern Standard Arabic*. Cambridge: Cambridge university press.
- Sagot, Benoit, and Geraldine Walther. 2010. A morphological lexian for the Persian language. In *Proceedings of the 7th Language Resources and Evaluation Conference (LREC'10)*. Malta.
- Shamsfard, M., H. S. Jafari, and M. Ilbeygi. 2010. *STeP-1: A Set of Fundamental Tools for Persian Text Processing*. In LREC 2010-8th Language Resources and Evaluation Conference. Malta.
- Torjmen, R. and K. Haddar. 2018. *Morphological analyzer for the Tunisian dialect*. In International Conference on Text, Speech, and Dialogue (pp. 180–187). Springer, Cham. Czech Republic.

داؤد حیدرپور

متولد سال ۱۳۶۲، دانش آموخته رشته نرم افزار و مترجمی زبان انگلیسی در مقطع کارشناسی و رشته زبان‌شناسی رایانشی در مقطع کارشناسی ارشد از دانشگاه تهران است. از جمله موضوعات تحقیقی مورد علاقه وی پردازش زبان طبیعی، متن کاوی و نظرکاوی است.



الهام سادات سبط

دارای مدرک کارشناسی فیزیک مهندسی و کارشناسی ارشد زبان‌شناسی رایانشی از دانشگاه تهران است. از جمله موضوعات تحقیقی مورد علاقه وی پردازش نحوی و ساخت‌وآری، نرمال‌سازی متن، طراحی و تهیه داده زبانی و مدل‌های ماتریسی در تحلیل نحوی (دستور ماتریسی) است.



محمود بی‌جن خان

متولد سال ۱۳۳۷، دارای مدرک تحصیلی دکتری در رشته زبان‌شناسی از دانشگاه تهران است. ایشان هم‌اکنون استاد تمام گروه زبان‌شناسی دانشگاه تهران است.

آواشناسی، واج‌شناسی، زبان‌شناسی پیکره‌ای، تولید پیکره‌های زبانی برای آموزش و ارزیابی سامانه‌های فناوری زبان از جمله علائق پژوهشی وی است.



مصطفی صالحی

دارای مدرک دکتری در رشته مهندسی کامپیوتر از دانشگاه صنعتی شریف است. ایشان هم‌اکنون عضو هیئت علمی دانشکده علوم و فنون نوین دانشگاه تهران است.

پایش رسانه‌های اجتماعی از جمله علائق پژوهشی وی است.



هادی ویسی

دارای مدرک دکتری مهندسی کامپیوتر از دانشگاه صنعتی شریف است. وی هم‌اکنون عضو هیئت علمی دانشکده علوم و فنون نوین دانشگاه تهران است.

هوش مصنوعی و زبان‌شناسی رایانشی از جمله علائق پژوهشی وی است.

