

بررسی مقایسه‌ای تأثیر بر چسب‌زنی مقوله‌های دستوری بر تجزیه در پردازش خودکار زبان فارسی

مسعود قیومی

گروه دستور زبان آلمانی، دانشگاه آزاد برلین، برلین، آلمان

پژوهشکده زبانشناسی، پژوهشگاه علوم انسانی و مطالعات فرهنگی، تهران، ایران



چکیده

در این مقاله، به بررسی جایگاه برچسبزنی مقوله‌های دستوری^۱ در تجزیهٔ نحوی خودکار^۲ جملات فارسی پرداخته خواهد شد. به همین منظور، تأثیر کیفیت برچسبزنی مقوله‌های دستوری و همچنین تأثیرگذاری میزان اطلاعات موجود در مقوله‌های دستوری بر کارآیی^۳ تجزیهٔ خودکار جملات مورد مطالعه قرار خواهد گرفت. به منظور انجام این دو بررسی، سه سناریو برای تجزیهٔ جملات، ارائه شده و مقایسه می‌شود. در سناریوی نخست، تجزیه‌گر ابتدا داده ورودی را برچسبزنی کرده و سپس جمله را تجزیه می‌کند. در سناریوی دوم، از یک برچسبزن خارج از تجزیه‌گر و در سناریوی سوم از برچسب معیار واژه‌ها برای تجزیهٔ جملات استفاده می‌شود. در این بررسی، معیارهای ارزیابی متفاوت مورد استفاده قرار می‌گیرد تا میزان این تأثیرگذاری از ابعاد مختلف نشان داده شود. نتایج حاصل از آزمایش‌ها نشان می‌دهد که کیفیت و میزان اطلاعات در مقولات دستوری واژه، بر کارآیی تجزیه‌گر تأثیر مستقیم دارد. کیفیت بالای برچسب مقوله‌های دستوری، سبب کاهش خطای تجزیه‌گر و افزایش کارآیی آن می‌شود؛ همچنین عدم وجود اطلاعات صرفی‌نحوی^۴ تأثیر منفی به سزاگیری بر کارآیی تجزیه‌گر دارد که این تأثیرگذاری در مقایسه با کیفیت برچسب مقولات دستوری بسیار بیشتر است.

واژگان کلیدی: پردازش زبان طبیعی، زبان فارسی، برچسبزنی مقوله‌های دستوری، تجزیهٔ نحوی خودکار، دانگی اطلاعات زبانشناسی

A Comparative Study on the Impact of Part-of-Speech Tagging on Parsing in Processing the Persian Language

Masoud Ghayoumi

German Grammar Group, Freie Universität Berlin, 14195 Berlin, Germany

Linguistics Department, Institute for Humanities and Cultural Studies, 14377, Tehran, Iran

Abstract:

In this paper, the role of Part-of-Speech (POS) tagging for parsing in automatic processing of the Persian language is studied. To this end, the impact of the quality of POS tagging as well as the impact of the quantity of information available in the POS tags on parsing are studied. To reach the goals, three parsing scenarios are proposed and compared. In the first scenario, the parser assigns the POS tags firstly and then it parses the input sentence. In the second scenario, an external POS tagger is used to assign the tags, then the sentence is parsed. In the third scenario, the parser uses the gold standard POS tags to parse the input sentence. In this study, various evaluation metrics are used to show the impacts from different points of views. The experimental results show that the quality of the POS tagger and the quantity of the information available in the POS tags have a direct effect on the parsing performance. The high quality of the POS tags causes error reduction in parsing and also it increases parsing performance. Moreover, lack of morphological -syntactic information in the POS tags has a high negative impact on parsing performance. This impact is more pronounced than the impact of POS tagger performance.

Keywords: natural language processing, the Persian language, part-of-speech tagging, parsing, granularity of linguistic information

۱- مقدمه

برچسبزنی مقولات دستوری نخستین مرحله پردازش نحوی جملات است که در آن نقش نحوی واژه مشخص می‌شود. برای برچسبزنی خودکار می‌توان از برچسبزن قاعده‌بنیان^۵، آماری، و یا ترکیبی^۶ استفاده کرد.

دو چالش در برچسبزنی خودکار واژه وجود دارد که برچسبزن می‌بایستی از عهده آن برآید. یکی از چالش‌ها، انتخاب بهترین برچسب برای واژه مبهم است که ممکن است آن واژه بیش از یک برچسب دستوری داشته باشد. چالش دیگر، پیشنهاد برچسب برای واژه‌های ناشناخته‌ای است که در قبل در داده آموزش دیده نشده است. این چالش بیشتر برای برچسبزن‌های آماری مطرح است. برای چیره‌شدن به هریک از این چالش‌ها روش‌هایی وجود دارد که خارج از بحث در این مقاله است؛ ولی تنها به این نکته می‌توان بسته کرد که بافت محلی واژه به حدس یا رفع ابهام مقوله دستوری واژه کمک شایانی می‌کند.

۲-۱- پیشینهٔ مطالعاتی برچسبزنی خودکار مقوله‌های دستوری در زبان فارسی

تا جایی که می‌دانیم، نخستین بررسی برای برچسبزنی واژه در زبان فارسی به صورت نیمه‌خودکار توسط عاصی و حاجی عبدالحسینی [9] در چارچوب کار پژوهشی معروفی شده توسط شوتر [37] طراحی و پیاده‌سازی شده است. آنها ۴۳ برچسب معرفی کرده و از داده پایگاه داده زبان فارسی [4] استفاده کرده‌اند.

مطالعات متنوعی در استفاده از روش‌های آماری برای برچسبزنی واژه‌های فارسی انجام شده است. متأسفانه مطالعه جامعی که مدل‌های ارائه شده را با هم مقایسه کند تا انتخاب بهترین مدل برای برچسبزنی واژها در فارسی را میسر سازد، وجود ندارد؛ بنابراین هریک از بررسی‌ها به خودی خود معتبر بوده که به اختصار به این مطالعات می‌پردازیم.

مدل احتمالات بیشینه^۷ برای برچسبدهی مقولات دستوری استفاده شده است [8],[29] که برای ساخت این مدل از پیکرۀ بی‌جن‌خان^۸ [1] که دارای ۵۸۶ برچسب است، به عنوان داده آموزش استفاده شده است. برچسبزن تی‌ان‌تی [12] یک برچسبزن آماری است که مستقل از

درک زبان طبیعی، یکی از مهم‌ترین بخش‌های پردازش زبان طبیعی است؛ چون در آن سعی می‌شود با تحلیل عمیق تر جملات به مفهوم دست یافته^۹ شود. درک زبان طبیعی در سه سطح نحوی، معنایی و کاربردشناسی اتفاق می‌افتد. برای رسیدن به مفهوم، نخستین گام تحلیل جملات در سطح^{۱۰} نحوی است تا رابطهٔ نحوی کلمات با یکدیگر در یک جمله مشخص شود. این سطح تحلیل شامل دو بخش است: بخش نخست مربوط به مشخص شدن نقش دستوری واژه در جمله است. در این بخش، مقولهٔ دستوری و ویژگی‌های معنایی واژه مشخص می‌شود. بخش دوم به نحوهٔ تعامل واژه‌ها با هم و ساخت یک جمله می‌پردازد. در کاربرد عادی یک سامانه، به این دو سطح تحلیل نیاز است تا زمینه برای درک عمیق‌تر جمله فراهم شود.

همان‌طور که مشخص است، دو بخش تحلیل در سطح نحو رابطهٔ تنگاتنگی با هم دارند و بخش دوم تأثیرگذیر از بخش نخست است. با نگاهی به مطالعات انجام‌شده بر روی زبان فارسی درمی‌باییم که هریک از این دو سطح به‌طور مستقل بررسی شده است. در این مقاله تلاش می‌کنیم، تعامل این دو بخش با یکدیگر و همچنین تأثیرگذاری مقولات دستوری را از دو جنبهٔ کیفیت و میزان اطلاعات بر تجزیه خودکار جملات بررسی کنیم. در انجام این بررسی، معیارهای ارزیابی متفاوتی را استفاده خواهیم کرد تا ابعاد تأثیرگذاری بهتر نمایان شود.

این مقاله در شش بخش نگارش شده است. بخش دو و سه به بیان کلیات و پیشینهٔ مطالعاتی برچسبزنی مقولات دستوری و تجزیهٔ نحوی می‌پردازد. در بخش چهار، معیارهای ارزیابی مورد استفاده در این مقاله معرفی می‌شود. ابزار و داده مورد نیاز این پژوهش و همچنین نتایج به‌دست آمده از آزمایش‌ها در بخش پنجم گزارش و توضیح داده می‌شود. در بخش ششم، خلاصه مقاله و نتیجه‌گیری حاصل از آزمایش‌ها بحث می‌شود.

۲- برچسبدهی مقولات دستوری

۲-۱- کلیات

^۱ Part-of-Speech Tagging

^۲ Syntactic Parsing

^۳ Performance

^۴ Morpho-syntactic

فصل نهم



^۵ Rule-based

^۶ Hybrid

^۷ Maximum Likelihood Estimation

^۸ <http://ece.ut.ac.ir/dbrg/bijankhan/>

ارائه کند. لازم به ذکر است که بحث و بررسی این روش‌ها از مقاله حاضر خارج است.

۲-۳- پیشینهٔ مطالعاتی تجزیهٔ خودکار در زبان فارسی

تجزیه‌گرهای (مبتنی بر سازه یا وابستگی) را می‌توان به سه دستهٔ اصلی قاعده‌بنیان، آماری و ترکیبی تقسیم کرد. در تجزیه‌گرهای دستهٔ نخست مجموعه‌ای از قواعد زبانی در چارچوب یک نظریهٔ زبانی گرددآوری می‌شود که جملات مربوط به آن قواعد را می‌تواند تجزیه کند؛ مانند تجزیه جملات با کمک تشخیص وابستگی‌ها [34]. تجزیه جملات در چارچوب دستور ارتباط^۳ [13]، تجزیه جملات در چارچوب دستور تعاملی^۴ [17]، تجزیه جملات در چارچوب دستور ساخت‌سازه‌ای هسته‌بنیان^۵ [28]، و تجزیه جملات در چارچوب دستور ساخت‌سازه‌ای تعمیم‌یافته^۶ [10]. علاوه‌بر این مطالعات، در پژوهشی دیگر شریفی آتشگاه [2] تلاش کرده است با استفاده از روش قاعده‌بنیان به‌طور نیمه‌خودکار جملات را تجزیه و دادگان درختی در چارچوب برنامهٔ کمینگی تهیه کند. نقطه‌ضعف این مطالعه این است که با وجود معرفی یک الگوریتم، تجزیه‌گر کاملی که بتواند تجزیه را در سطح جمله ارائه کند تهیه نشده و کار عملی این مطالعه در سطح تجزیه‌گروه‌ای اسمی باقی مانده است.

تجزیه‌گرهای دستهٔ دوم مستقل از زبان بوده و با استفاده از مدل‌های آماری-احتمالاتی جملات را تجزیه می‌کند. دو روش متفاوت در آموزش این دسته از تجزیه‌گرها وجود دارد: (۱) روش بی‌مربی^۷ که به داده آموزش اولیه نیازی ندارد. فیلی [5] در رسالهٔ دکترای خود به ابداع روشی برای تهیه یک تجزیه‌گر بی‌مربی آماری برای تشخیص ساخت‌سازه‌ای سازه‌ای پرداخته است. رسولی و فیلی [31] نیز سعی کرده‌اند به صورت بی‌مربی، وابستگی بین واژه‌های فارسی را تشخیص دهنند تا تجزیه جملات حاصل شود. (۲) روش بامربی که نیازمند داده آموزش اولیه است. در چند ساخت‌سازه‌ای سازه‌ای تجزیه‌گر آماری بامربی سازه‌ای زبان فارسی از دادگان درختی تهیه شده زبان فارسی [15] استفاده شده است [6]. در پژوهش‌های دیگری، دادگان درختی وابستگی تهیه شده و از آن برای آموزش تجزیه‌گر آماری بامربی وابستگی استفاده شده است [18], [32], [39].

³ Link Grammar

⁴ Interaction Grammar

⁵ Head-driven Phrase Structure Grammar

⁶ Generalized Phrase Structured Grammar

⁷ Unsupervised

زبان بوده و با پیکرهٔ بی‌جن‌خان آموزش دیده است [41]. در یک مدل برچسبزنی دیگر، از یک روش ترکیبی برای تحلیل صرف استفاده شده است [40]. تعداد برچسب‌های معرفی شده در این پژوهش ۲۵ برچسب است واز پیکرهٔ همشهری [8] در این پژوهش استفاده شده است. محسنهٔ و مینایی‌بیدگلی [27] یک تحلیل‌گر صرفی برای برچسبزنی تهیه کرده‌اند؛ به صورتی که در این پژوهش، تعداد برچسب‌های پیکرهٔ بی‌جن‌خان از ۵۸۶ برچسب به ۱۰۵ برچسب کاهش یافته است. سراجی [38] نیز یک برچسبزن زبان مجارستانی را با پیکرهٔ بی‌جن‌خان آموزش داده و از آن برای برچسبزنی متن فارسی استفاده کرده است. دنیس و زگوت [14] از سامانهٔ Melt برای برچسبزنی استفاده کرده‌اند. آنها در پژوهش خود برچسب‌های موجود در پیکرهٔ بی‌جن‌خان را با توجه به نیاز تغییر داده‌اند.

۳- تجزیهٔ خودکار

۱-۳- کلیات

تجزیهٔ خودکار مرحلهٔ پیچیده‌تر پردازش نحوی جملات است؛ چون در این سطح تحلیل، روابط واژه‌ها با یکدیگر برای ساخت یک جمله مشخص می‌شود. برای این منظور درجه‌ای از تجزیهٔ جمله می‌تواند ارائه شود. برای این منظور می‌توان از تجزیه‌گر قاعده‌بنیان، آماری، و یا ترکیبی استفاده کرد. دو دیدگاه و شیوهٔ به طور کامل متفاوت در ارائهٔ تجزیهٔ نحوی جملات مطرح است: یک دیدگاه مبتنی بر سازه (جاشنختی^۱) و دیدگاه دیگر مبتنی بر وابستگی (ساختار دستوری^۲) است.

در این مقاله، دیدگاه جاشنختی و تجزیهٔ ساخت‌سازه‌ای جملات مدنظر است. در پردازش و تجزیهٔ ساخت‌سازه‌ای جملات دو چالش وجود دارد. یکی از این دو چالش، رفع ابهام در اتصال سازه‌های کوچک‌تر برای ساخت سازه‌های بزرگ‌تر است که ابهام ساختاری جمله در این سطح مطرح است. چالش دیگر، رفع ابهام برای یافتن برچسب صحیحی است که بیان گر رابطهٔ واژه‌ها با هم و ساخت یک سازهٔ دستوری است. برای رفع ابهام این دو چالش، روش‌ها و الگوریتم‌های مختلفی، مانند تجزیهٔ بالابه‌پایین یا پایین‌به‌بالا [21]، وجود دارد که سعی می‌کند بهترین تجزیهٔ نحوی را بیابد و آن را به عنوان بهترین تجزیه

¹ Typological

² Tecto-grammatical

البته علاوه بر ارزیابی اتصال گرهای در ساخت‌سازه، می‌توان بر جسب آن سازه را نیز دخیل کرد تا ارزیابی جامع‌تری صورت پذیرد. بر همین اساس، «صحت برچسب‌دار^۷» و «پوشش برچسب‌دار^۸» مطرح می‌شود. «تناظر همسان^۹» یک معیار قوی است که امتیاز یک را به تجزیه‌ای که به طور کامل صحیح باشد، می‌دهد و در غیر این صورت امتیاز صفر می‌دهد.

مشکلی که در بررسی سمپسون [33] در مورد ارزیابی صحت و پوشش عنوان می‌شود، این است که اگر اشتباهی در یک سازه روی دهد، می‌بایستی فقط بر امتیاز آن واژه در آن سازه و نه بر امتیاز ارزیابی تمام جمله تأثیر گذارد. بر همین اساس، وی معیاری را با عنوان «نیای برگ^{۱۰}» معرفی می‌کند. در این معیار، فاصله واژه تا ریشه درخت تجزیه با توجه به درخت تجزیه معیار جمله محاسبه شده و معدل این امتیاز به عنوان امتیاز نیای برگ تلقی می‌شود. برای محاسبه این فاصله، از فاصله لونشتاین^{۱۱} [25] استفاده می‌شود. این امتیاز بیان‌گر میزان تلاش مورد نیاز برای تغییر برچسب سازه‌ای اشتباه به برچسب صحیح است.

نقاطه ضعف نیای برگ این است که تعداد قلابها در تحلیل درختی نقش زیادی دارد. بر همین اساس، لین [26] معیاری را معرفی می‌کند که در آن تحلیل سازه‌ای جمله به معادل تحلیل وابستگی آن جمله تبدیل می‌شود و وابستگی عناصر با هسته به جای ساختار سازه‌ای سلسله‌مراتبی ارزیابی می‌شود. در این نحوه ارزیابی، با در نظرداشتن وجود برچسب وابستگی^{۱۲} یا عدم وجود آن^{۱۳} برای تک‌تک واژه‌ها، روابط وابستگی بین واژه‌ها ارزیابی می‌شود. در ارزیابی کارآیی تجزیه‌گر براساس روابط وابستگی، شکل ساده‌ای از تجزیه جمله مورد توجه قرار می‌گیرد.

۵- نتایج

۱-۵- مقدمه‌سازی برای انجام آزمایش‌ها

۱-۱-۵- ابزار

همان‌طور که در مقدمه مقاله ذکر شد، هدف این مقاله بررسی تأثیرگذاری برچسب مقولات دستوری بر تجزیه

⁷ Labeled Precision

⁸ Labeled Recall

⁹ Exact Matching

¹⁰ Leaf Ancestor

¹¹ Levenshtein Distance

¹² Labeled Attachment

¹³ Unlabeled Attachment

به‌هنگام آموزش تجزیه‌گرهای آماری می‌توان ویژگی‌های^۱ به‌کاررفته در مدل دستوری را تغییر داد که این تغییر بر کارآیی تجزیه‌گر تأثیرگذار خواهد بود. از جمله این ویژگی‌ها، دانه‌درشتی و دانه‌درشتی ویژگی‌های صرفی و واژگانی است که در چندین مطالعه تأثیر دانه‌درشتی یا دانه‌درشتی واژه بر کارآیی تجزیه‌گر سازه‌ای در زبان‌های فارسی و بلغاری بررسی شده است [16],[19],[20]. در مطالعه دیگر تأثیر ویژگی‌های صرفی، معنایی، دانه‌درشتی و دانه‌درشتی آنها بر تجزیه‌گر وابستگی فارسی بررسی شده است [22]. همچنین، طول جمله نیز از دیگر عوامل تأثیرگذار بر کارآیی تجزیه‌گر است که مورد بررسی قرار گرفته است [3].

۴- معیارهای ارزیابی

برای ارزیابی کارآیی برچسبزن و تجزیه‌گر معیارهای متفاوتی معرفی شده است. ارزیابی دقت برچسبزنی ساده است و به طور معمول از معیار دقت^۲ استفاده می‌شود. این معیار براساس نسبت تعداد کلماتی که صحیح برچسب‌گذاری شده به تعداد کل کلمات برچسب‌گذاری شده محاسبه می‌شود.

معیارهای ارزیابی تجزیه‌گر سازه‌ای تنوع بیشتری دارد؛ که در اینجا به چند مورد آن اشاره خواهیم کرد تا با در نظر گرفتن معیار ارزیابی تجزیه‌گر، تأثیر برچسب مقولات دستوری بر تجزیه‌گر مشخص شود. از جمله معیارهای متداول برای ارزیابی کارآیی تجزیه‌گر آماری صحت^۳ (رابطه ۱)، پوشش^۴ (رابطه ۲)، و امتیاز تأثیر این دو معیار^۵ (رابطه ۳) را می‌توان نام برد.^۶

$$P = \frac{\text{num. of correct constituents}}{\text{num. of cons.s in parser output}} \quad (1)$$

$$R = \frac{\text{num. of correct constituents}}{\text{num. of cons.s in gold standard}} \quad (2)$$

$$f_1 = \frac{2 \times P \times R}{P+R} \quad (3)$$

¹ Feature

² Accuracy

³ Precision

⁴ Recall

⁵ F-measure

⁶ نویسنده مقاله پیش‌تر در [۶] از معادل فارسی «دقت» برای «recall» استفاده کرده است. برای رفع ابهام این مفهوم در مقایسه با معادل فارسی «دقت» برای «accuracy»، معادل فارسی «پوشش» برای «recall» پیشنهاد می‌شود.



در برچسب‌های پیکره بی جن خان، دو کاستی و مشکل وجود دارد. مشکل نخست این است که طول برچسب‌ها متفاوت است. براساس جدول (۱)، طول برچسب‌ها بین سه تا پنج برچسب متغیر است. مشکل دوم که متأثر از مشکل نخست است این است که جایگاه هر اطلاع ثابت نیست. همان‌گونه که در جدول (۱) دیده می‌شود، جایگاه واژه‌بست و اطلاعات معنایی در یک جایگاه ظاهر شده است که از نظر منطقی قبل‌پذیرش نیست؛ چون محتواهای این دو برچسب متفاوت است. به دلیل این دو کاستی و مشکل، قالب برچسب‌های پیکره بی جن خان به چارچوب ^۵MulText-East تبدیل شده است که نمونه این تغییرات در جدول (۲) آمده است [15].

(جدول -۲): برچسب واژه «دفتر» در پیکره بی جن خان و دادگان درختی زبان فارسی

(Table-2): POS tag of the word «دفتر» /daftar/ in the Bijankhan Corpus and the Persian Treebank

برچسب تبدیل شده	برچسب اصلی	واژه
Ncsp—	N,COM,SING	دفتر
Ncsp-z	N,COM,SING,EZ	دفتر
Ncspk—	N,COM,SING,LOC	دفتر
Ncspk-z	N,COM,SING,LOC,EZ	دفتر

در برچسب‌های تبدیل شده جدول (۲)، طول برچسب برای اسم، هفت بوده و در تمام واژه‌های اسم یکسان است. در این شکل جدید برچسب، جایگاه نخست متعلق به مقوله دستوری اصلی واژه است. در جایگاه دوم نوع اسم از نظر عام و خاص مشخص می‌شود. جایگاه سوم مختص شمار است. قطبیت مثبت یا منفی در جایگاه چهارم ظاهر می‌شود. جایگاه پنجم برای ویژگی‌های معنایی است که بیشتر برای ابهام‌زدایی همنویسه‌ها به کار رفته است، جایگاه ششم برای اختصار و جایگاه هفتم متعلق به واژه‌بست است. براساس جدول (۲)، میزان اطلاعات زبان‌شناختی برچسب‌های دستوری در پیکره بی جن خان و دادگان درختی زبان فارسی تهیه شده توسط قیومی [15] یکسان و فقط نحوه نمایش آن با رفع کاستی‌ها تغییر یافته است.

برای آموزش تجزیه‌گر سازه‌ای آماری، از دادگان درختی تهیه شده توسط قیومی [15] که شامل ۱۰۲۸ جمله

^۵ <http://nl.ijs.si/ME/>

خودکار است. در این پژوهش برای انجام آزمایش‌ها از ابزارهای آماری مانند برچسب‌زن تی ان. تی ^۱ [12]، برچسب‌زن استنفورد ^۲ [42]، تجزیه‌گر استنفورد ^۳ [23]، تجزیه‌گر بِرُکلی ^۴ [30]، و تجزیه‌گر بیتپر ^۵ [36] استفاده می‌کنیم. تجزیه‌گر استنفورد یک تجزیه‌گر آماری واژگانی است؛ ولی تجزیه‌گرهای بِرُکلی و بیتپر آماری غیرواژگانی هستند. هدف استفاده از ابزار متفاوت، بیان این نکته است که شیوه و الگوریتم استفاده شده در هریک از ابزارها می‌تواند در نتیجه نهایی تأثیرگذار باشد. لازم به ذکر است که بررسی این تأثیرگذاری در روند محاسباتی داخل برچسب‌زن و تجزیه‌گر و مدل ساخته شده از داده آموزش خارج از بحث مقاله حاضر است و در این مقاله فقط به مقایسه خروجی و کارآیی آن‌ها می‌پردازیم.

۲-۱-۵ داده آموزش

برای آموزش برچسب‌زن از پیکره برچسب‌گذاری شده بی جن خان [1] استفاده می‌کنیم. ویژگی این پیکره این است که اطلاعات صرفی-نحوی و معنایی برای واژه‌های پیکره وجود دارد. ساختار برچسب‌ها به صورت سلسله‌مراتبی بوده و براساس دستورالعمل لیچ و ویلسون [24] تهیه شده است. در برچسب واژه‌ها، علاوه بر اطلاعات دستوری شامل اسم، صفت، فعل، و غیره، اطلاعات صرفی در مورد واژه‌ها از جمله اضافه و شخص و شمار نیز وجود دارد. ویژگی معنایی نیز با هدف نشان دادن تمایز معنایی همنویسه‌ها استفاده شده است [11]. با درنظر گرفتن این حجم از اطلاعات، ۵۸۶ برچسب به دست آمده است که ابهام‌زدایی این تعداد برچسب، کار برچسب‌زن را دشوار کرده و می‌تواند بر دقت آن تأثیر منفی بگذارد. جدول (۱)، نمونه‌هایی از ترتیب اطلاعات صرفی-نحوی و معنایی در برچسب‌های پیکره بی جن خان را نمایش می‌دهد.

(جدول -۱): برچسب واژه «دفتر» در پیکره بی جن خان

(Table-1): POS tag of the word «دفتر» /daftar/ in the Bijankhan Corpus

برچسب اصلی در پیکره	واژه
N,COM,SING	دفتر
N,COM,SING,EZ	دفتر
N,COM,SING,LOC	دفتر
N,COM,SING,LOC,EZ	دفتر

^۱ TnT Part-of-Speech Tagger

^۲ Stanford Part-of-Speech Tagger

^۳ Stanford Parser

^۴ Berkley Parser



۵-۲-۵- ارزیابی

در انجام آزمایش‌ها، سه سناریو پیشنهاد می‌شود تا تصویر واضح‌تری از اثرگذاری برچسب مقوله‌های دستوری بر تجزیه ارائه شود.

در سناریوی نخست، تجزیه‌گر با داده آموزش حاصل از دادگان درختی آموزش می‌بیند و سپس داده آزمون به صورت خام به آن داده می‌شود. چالش این سناریو این است که تجزیه‌گر می‌بایستی با توجه به داده آموزش، ابتدا به داده آزمون ورودی برچسب مقوله‌ای دستوری بزند و سپس شروع به تجزیه جمله کند. این سناریو، صورت عادی کاربرد تجزیه‌گر است. نتایج حاصل از این آزمایش در جدول (۳) آمده است. مشکل سناریوی نخست این است که به دلیل کمبود داده آموزش، مدل خوبی برای برچسب‌زنی ساخته نشده و اشتباه در برچسب مقولات دستوری واژه‌ها منجر به اشتباه و کاهش کارآیی تجزیه‌گر می‌شود. برای بررسی عینی‌تر، دقت برچسب‌زن تجزیه‌گرها را محاسبه کرده‌ایم که نتایج آن در جدول (۴) گزارش شده است. همان‌طور که از نتایج این جدول بر می‌آید، برچسب‌زنی این تجزیه‌گرها دقت بالایی ندارد که این امر سبب گمراحت‌ساختن تجزیه‌گر می‌شود. به دلیل دقت پایین برچسب مقولات دستوری، سناریوی دوم مطرح می‌شود.

در سناریوی دوم، تجزیه‌گر با داده آموزش حاصل از دادگان درختی آموزش می‌بیند و سپس داده آزمون که به صورت مجزا برچسب‌زنی شده است به آن داده می‌شود. در این سناریو، تجزیه‌گر تنها به تجزیه جمله می‌پردازد و دخالتی در برچسب مقولات دستوری ندارد. به منظور برچسب‌زنی داده آزمون در این سناریو، از یک برچسب‌زن خارج از تجزیه‌گر مانند تی-ان-تی یا استنفورد استفاده شده و آن‌ها را با پیکره برچسب‌زده‌شده‌ی جن‌خان آموزش می‌دهیم. از آنجاکه این پیکره بسیار بزرگ‌تر از دادگان درختی است، انتظار می‌رود فرآیند برچسب‌زنی با دقت بسیار بالاتری صورت پذیرد. گفتنی است که جملات موجود در دادگان درختی از پیکره آموزش برچسب‌زن حذف شده و به عنوان داده آزمون به برچسب‌زن داده می‌شود تا هیچ‌گونه هم‌پوشی بین داده آموزش و آزمون برچسب‌زن نباشد.

میزان اطلاعات در برچسب مقولات دستوری می‌تواند کلی (دانه-درشت^۷) یا جزئی (دانه-ریز^۸) باشد. در جدول (۵) اطلاعات مربوط به داده آزمون سناریوی دوم نمایش داده

⁷ Coarse-grained

⁸ Fine-grained

است، استفاده می‌کنیم. این دادگان نخستین دادگان درختی تهیه شده برای زبان فارسی و تنها دادگانی است که براساس دستور ساخت‌سازهای هسته‌بنیان تهیه شده و به طور رایگان موجود است.^۱ ویژگی این داده این است که علاوه‌بر تحلیل سلسه‌مراتبی ساخت‌سازهای هر جمله، نوع رابطه عناصر و سازه‌ها با هسته از نظر رابطهٔ فاعلی، متممی، یا آویزه مشخص شده است. اگرچه این اطلاعات تحلیل عمیق‌تری از جمله ارائه می‌کند، علاوه‌بر تجزیه سلسه‌مراتبی ساخت جمله و برچسب‌زنی گره‌ها، ابهام‌زدایی در تشخیص نوع رابطه وابستگی در سازه نیز می‌بایستی صورت گیرد که سبب افزایش دشواری تجزیه‌گر شده و ممکن است، منجر به کاهش کارآیی آن شود. شکل (۱)، نمونه درخت تجزیه جمله «بورن به‌اتفاق پدرش به پراگ مهاجرت کرد.» را نمایش می‌دهد. همان‌گونه که در شکل نشان داده شده است، علاوه‌بر برچسب گره هر سازه، مانند NP، VP، PP، نوع رابطه وابستگی سازه که بین هسته و واژه دیگر وجود دارد، مشخص شده است. برای مثال، اگر در یک سازه، هسته گروه اسمی واژه دیگر را جزء موضوع^۲ هسته انتخاب کند، آن واژه به عنوان متمم^۳ هسته تلقی شده و برچسب NPC انتخاب می‌شود. چنانچه واژه دیگر سازه جزء موضوع هسته نباشد، آن واژه آویزه^۴ است و رابطه وابستگی بین عناصر این سازه آویزه‌ای است و برچسب NPA انتخاب می‌شود.

برای ارزیابی «صحت برچسب‌دار» و «پوشش برچسب‌دار» از ابزار Evalb^۵ استفاده می‌کنیم. برای ارزیابی کارآیی تجزیه‌گر براساس روابط وابستگی، نیاز به تبدیل خودکار تجزیه سازه‌ای به وابستگی است که برای این منظور از الگوریتم معرفی شده توسط قیومی و کوهن [۱۸] استفاده می‌کنیم.

برای محاسبه کارآیی تجزیه‌گر از «ارزیابی حد وسط ۱۰ تایی»^۶ استفاده می‌کنیم. در این روش، کل داده موجود به ده قسمت بدون هم‌پوشی تقسیم شده، و در هر مرحله یکی از این قسمتها به عنوان داده آزمون برای ارزیابی و ۹ قسمت دیگر برای آموزش استفاده می‌شود. در انجام آزمایش‌ها، تمام جملات داده آموزش و آزمون بدون هرگونه پالایشی مانند حذف جملات بلند یا حذف مقوله‌های تهیه مورد استفاده قرار گرفته است.

¹ <http://hpsg.fu-berlin.de/~ghayoomi/PTB.html>

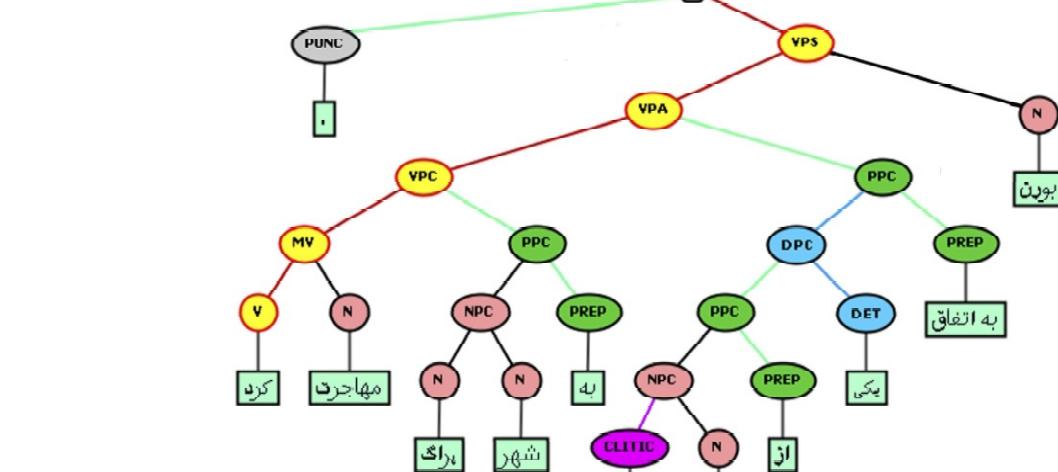
² Argument

³ Complement

⁴ Adjunct

⁵ <http://nlp.cs.nyu.edu/evalb/>

⁶ 10-fold cross validation



(شکل-۱): نمونه درخت تحلیل از دادگان درختی زبان فارسی
(Figure-1): Sample tree analysis from the Persian Treebank

استنفورد و داده آزمون یکسان برای هر دو آزمایش استفاده شده است. تنها تفاوت این دو آزمایش در داده آموزش برچسبزن است که در سناریوی نخست فقط از جملات دادگان درختی تهیه شده زبان فارسی، و در سناریوی دوم از جملات پیکره بی جن خان استفاده شده است. مقایسه نتایج گویای این است که افزایش حجم داده آموزش در سناریوی دوم سبب افزایش ۹/۸۲ درصدی نسبت به سناریوی نخست در دقت برچسبزن شده است.

سناریوی دوم می‌تواند مدل دو مرحله‌ای از کاربرد عادی تجزیه‌گر باشد؛ ولی همچنان ظرفیت برای ارتقای کیفیت دقت تجزیه‌گر وجود دارد. بر همین اساس سناریوی سوم که در آن نهایت دقت برچسب مقولات دستوری به کار رفته است پیشنهاد می‌شود تا حد نهایی کارآیی تجزیه‌گر مشخص شود و زمینه پژوهش را با هدف ارائه روش‌هایی برای بهبود کارآیی تجزیه‌گر در مطالعات آینده فراهم آورد.

در سناریوی سوم، تجزیه‌گر با داده آموزش حاصل از دادگان درختی آموزش می‌بیند و سپس داده آزمون برچسبزده شده به آن داده می‌شود. در این سناریوی از برچسبزن خارجی استفاده نمی‌شود؛ بلکه برچسب معیار به واژه‌ها ملحق شده، و تجزیه‌گر مجبور به استفاده از این برچسب‌ها است. نتایج حاصل از سناریوی سوم در جدول (۸) آمده است.

از مقایسه جداول (۳)، (۷) و (۸) می‌توان به این نتیجه رسید که کیفیت برچسب مقولات دستوری به طور مستقیم بر کارآیی تجزیه‌گر مؤثر است؛ زیرا با بهبود کیفیت برچسب‌ها، کارآیی تجزیه‌گرها با الگوریتم‌های متفاوت افزایش می‌یابد. این تأثیر مثبت در تمام معیارهای ارزیابی قابل مشاهده است.

شده است. همان‌طور که مشاهده می‌شود، تغییر در میزان اطلاعات برچسب مقولات دستوری سبب تغییر در تعداد برچسب‌ها می‌شود که نتیجه آن آسانی یا پیچیدگی کار برچسبزن بوده و بر دقت برچسبزن تأثیرگذار است. در جدول (۶)، دقت برچسبزن‌های خارجی تیان-تی و استنفورد در سناریوی دوم با توجه به دو سطح اطلاع دانه‌ریزی و دانه‌درشتی مقولات دستوری نمایش داده شده است. از مقایسه دقت برچسبزن‌ها با استفاده از اطلاعات دانه‌ریز در جدول (۴) و (۶) در می‌یابیم که افزایش حجم داده آموزش بر افزایش دقت برچسبزن تأثیر مستقیم دارد که در ادامه این بخش با انجام آزمایش‌هایی این نکته بررسی می‌شود.

از آنجاکه دقت برچسبزن استنفورد بیشتر از تیان-تی است، از برچسبزن استنفورد برای انجام آزمایش‌های سناریوی دوم استفاده می‌شود. نتایج حاصل از آزمایش‌های سناریوی دوم در جدول (۷) آمده است. از مقایسه جدول (۳) و (۷) در می‌یابیم که بهبود کیفیت برچسب مقولات دستوری واژه‌ها بر کارآیی تجزیه‌گر تأثیر مستقیم دارد. این تأثیر در تمامی معیارهای ارزیابی قابل مشاهده است.

گفته شد که افزایش حجم داده آموزش برچسبزن بر افزایش دقت آن تأثیرگذار است. برای این منظور، آزمایشی را انجام داده‌ایم که در آن دقت برچسبزن در سناریوی نخست و دوم مقایسه می‌شود. برای بی‌اثرکردن تأثیر ابزار و نحوه استخراج ویژگی‌ها و همچنین حجم داده آزمون به عنوان متغیر بر دقت، از برچسبزن خارجی

ایده‌آل مورد توجه قرار گیرد. سناریوی سوم نشان دهنده نتایجی است که می‌توان از تجزیه‌گر در شرایطی به دست آورد که برچسبزن هیچ خطایی نداشته باشد. این سناریو در کاربرد واقعی قابل پیاده‌سازی نیست؛ ولی می‌تواند برای انجام آزمایش‌های مختلفی که سعی در بهبود کارآیی تجزیه‌گر دارد، مورد استفاده قرار گیرد.

با مقایسه سناریوهای معرفی شده، ذکر این نکته حائز اهمیت است که اگرچه سناریوی نخست به صورت پیش‌فرض در بیش‌تر کاربردهای عادی تجزیه‌گر مورد استفاده قرار می‌گیرد، دقت بالاتر برچسبزن و کارآیی بالاتر تجزیه‌گر در سناریوی دوم نشان دهنده ارزش تلاش بیشتر برای پیاده‌سازی سناریوی دوم است تا این سناریو به عنوان کاربرد

جدول-۳: نتایج حاصل از آزمایش‌های سناریویک

(Table-3): Experimental results of the first scenario

وابستگی		نیای برگ	تناظر همسان	امتیاز تأثیر صحت و پوشش	پوشش	صحت	تجزیه‌گر
با برچسب	بدون برچسب						
56.75	65.74	82.11	3.229	46.90	46.86	46.93	استنفورد
59.63	67.63	81.57	5.219	54.95	54.76	55.11	برنکلی
62.94	72.08	84.67	5.016	58.86	58.49	59.34	بیتپر

جدول-۴: ارزیابی دقت برچسبزن تجزیه‌گر (دانه‌دریز)

(Table-4): Evaluation of the parsers' POS tagging (fine-grained)

دقت	تجزیه‌گر
74.67	استنفورد
73.72	برنکلی
73.79	بیتپر

جدول-۵: اطلاعات مربوط به داده آزمون

(Table-5): Test data information

میزان اطلاعات	تعداد برچسب	تعداد واژه غیرتکرار	تعداد واژه ناشناخته	تعداد واژه‌های ناشناخته
دانه‌ریز	247	5700	27026	513
	15			دانه‌درشت

جدول-۶: ارزیابی دقت در برچسبزنی کلمات

(Table-6): Evaluation of POS-tagging accuracy

دقت	میزان اطلاعات	برچسبزن
81.48	دانه‌ریز	تی‌إن-تی
95.70	دانه‌درشت	
95.90	دانه‌ریز	استنفورد
98.37	دانه‌درشت	

جدول-۷: نتایج حاصل از آزمایش‌های سناریوی دوم

(Table-7): Experimental results of the second scenario

وابستگی		نیای برگ	تناظر همسان	امتیاز تأثیر صحت و پوشش	پوشش	صحت	تجزیه‌گر
با برچسب	بدون برچسب						
57.58	66.55	82.30	4.167	52.43	52.30	52.65	استنفورد
63.06	70.39	81.90	6.9	57.59	57.66	57.53	برنکلی
69.53	76.39	85.49	8.495	63.68	63.31	64.16	بیتپر



جدول-۸: نتایج حاصل از آزمایش‌های سناریوی سوم
(Table-8): Experimental results of the third scenario

وابستگی		نیای برگ	تناظر همسان	امتیاز تأثیر صحت و پوشش	پوشش	صحت	تجزیه‌گر
با برچسب	بدون برچسب						
63.69	72.44	85.65	4.992	59.42	59.40	59.44	استنفورد
66.96	73.36	83.51	8.485	62.27	62.28	62.25	برُکلی
78.58	84.56	89.78	10.354	70.92	70.43	71.49	بیتپر

جدول-۹: ارزیابی تأثیر میزان اطلاعات مقولات دستوری بر تجزیه
(Table-9): Evaluation of the impact of POS tag information on parsing

وابستگی		نیای برگ	تناظر همسان	امتیاز تأثیر صحت و پوشش	پوشش	صحت	میزان اطلاعات	تجزیه‌گر
با برچسب	بدون برچسب							
63.69	72.44	85.65	4.992	59.42	59.40	59.44	دانه‌ریز	استنفورد
50.82	59.55	80.64	4.046	47.38	47.37	47.39	دانه‌درشت	
66.96	73.36	83.51	8.485	62.27	62.28	62.25	دانه‌ریز	برُکلی
50.50	58.96	79.79	3.013	47.12	47.05	47.18	دانه‌درشت	
78.58	84.56	89.78	10.354	70.92	70.43	71.49	دانه‌ریز	بیتپر
54.16	61.13	81.16	3.651	51.19	51.37	51.16	دانه‌درشت	

حاصل از این آزمایش در جدول (۹) آمده است. همان‌طور که مشاهده می‌شود در آزمایش‌هایی که میزان اطلاعات مقوله‌های دستوری دانه‌ریز است، کارآیی هر سه تجزیه‌گر استنفورد، برُکلی، و بیتپر بیشتر از آزمایش‌هایی است که میزان اطلاعات مقولات دستوری دانه‌درشت است. بر همین اساس، نتایج گزارش شده در جدول (۹) گویای این نکته است که افزایش میزان اطلاعات صرفی-نحوی موجود در برچسب مقوله‌های دستوری بر افزایش کارآیی تجزیه‌گر تأثیر مستقیم دارد و این تأثیر در معیارهای ارزیابی متفاوت قابل مشاهده است. با بررسی میزان این تأثیر، می‌توان به این نتیجه دست یافت که هرچند دقیق برچسب‌زن صد درصد باشد، میزان اطلاعات صرفی-نحوی مقولات دستوری تأثیر بسیار بیشتری بر کارآیی تجزیه‌گر نسبت به دقیق برچسب‌ها دارد.

۶- نتیجه‌گیری

در این مقاله تأثیر کیفیت و میزان اطلاعات مقوله‌های دستوری بر تجزیه خودکار بررسی شد. به‌همین‌منظور، سه سناریوی برای تجزیه خودکار جملات پیشنهاد شد. در سناریوی نخست، تجزیه‌گر ابتدا می‌بایستی داده ورودی را

با مقایسه تجزیه‌گرهای متفاوت استفاده شده در انجام آزمایش‌ها، مشاهده می‌شود که تجزیه‌گر بیتپر کارآیی بالاتری را نسبت به تجزیه‌گرهای استنفورد و برُکلی به دست آورده است؛ با این تفاوت که به صورت عملی دریافتیم تجزیه‌گر استنفورد مقاوم‌تر^۱ از تجزیه‌گر برُکلی و بیتپر است؛ چون این تجزیه‌گر تجزیه‌ای را برای تمام جملات ارائه کرده است، در حالی که دو تجزیه‌گر دیگر قادر به تجزیه حدود ۱۰ درصد جملات داده آزمون نبودند.

همان‌طور که گفته شد، میزان اطلاعات مقوله‌های دستوری می‌تواند در دو سطح دانه‌ریز یا دانه‌درشت برچسب‌زنی شود که میزان اطلاعات این دو سطح می‌تواند بر کارآیی تجزیه‌گر تأثیرگذار باشد. برای بررسی تأثیر میزان اطلاعات مقوله دستوری در دو سطح دانه‌ریزی یا دانه‌درشتی، آزمایش‌های دیگری را انجام داده‌ایم. در این سری آزمایش‌ها، اطلاعات مقوله‌های دستوری از دانه‌ریزی به دانه‌درشتی کاهش می‌یابد. اگرچه سناریوی دوم صورت ایده‌آل کاربرد تحلیل نحوی در پردازش زبان است، برای خنثی کردن تأثیر منفی کیفیت برچسب واژه بر تجزیه جمله این آزمایش در چارچوب سناریوی سوم انجام می‌شود. نتایج

^۱Robust

dissertation, Sharif University of Technology, Tehran, Iran, 2006.

[۶] م. قیومی، ”معرفی دادگان درختی و تجزیه درختی فارسی“، در مجموعه مقالات هشتمین کنفرانس زبانشناسی ایران، جلد ۲، صص. ۱۳۹۲-۶۷۹-۶۶۶.

M. Ghayoomi, “mo’arrefiyé dādegāne deraxti va tažiyegare xodkāre fārsi [Introducing a treebank and a statistical parser for Persian],” In *Proceedings of the 8th Conference of Iranian Linguistics*, Allāme Tabātabāyi University, vol. 2, pp. 666-679, 2013.

[۷] A. AleAhmad *et al.*, “Hamshahri: A standard Persian text collection,” *Knowledge-Based Systems*, vol. 22, no. 5, pp. 382-387, 2009.

[۸] H. Amiri *et al.*, “Investigation on a feasible corpus for Persian POS tagging,” In *Proceedings of the 12th International CSI Computer Conference*, Iran, 2007.

[۹] M. Assi and M. HajiAbdolhosseini, “Grammatical tagging of a Persian corpus,” *International Journal of Corpus Linguistics*, vol. 5, no. 1, pp. 69-82, 2000.

[۱۰] M. Bahrami *et al.*, “A computational grammar for Persian based on GPSG,” *Language Resources and Evaluation*, vol. 45, no. 4, pp. 387-408, 2011.

[۱۱] M. Bijankhan *et al.*, “Lessons from building a Persian written corpus: Peykare,” *Language Resources and Evaluation*, vol. 45, no. 2, pp. 143-164, 2011.

[۱۲] T. Brants, “TnT - A statistical part-of-speech tagger,” In *Proceedings of the Association for Neuro-Linguistic Programming and NAACL*, pp. 224-231, 2000.

[۱۳] J. Dehdari and D. Lonsdale, “A link grammar parser for Persian,” In *Aspects of Iranian Linguistics*, S. Karimi, V. Samiian, and D. Stilo, Eds. Cambridge Scholars Press, vol. 1, 2008.

[۱۴] P. Denis and B. Sagot, “Coupling an annotated corpus and a morpho-syntactic lexicon for state-of-the-art POS tagging with less human effort,” In *Pacific Asia Conference on Language, Information and Computation*, Hong Kong, Chine, 2009.

[۱۵] M. Ghayoomi, “Bootstrapping the development of an HPSG-based treebank for Persian,” *Linguistic Issues in Language Technology*, vol. 7, no. 1, 2012.

[۱۶] M. Ghayoomi, “Word clustering for Persian statistical parsing,” *Advances in Natural Language Processing*, volume 7614 of Lecture Notes in Computer Science: JapTAL ’12: Proceedings of the 8th International Conference on Advances in Natural Language Processing, Springer Berlin Heidelberg, pp. 126-137, 2012.

برچسبزنی کرده و سپس جمله را تجزیه کند. در سناریوی دوم، از یک برچسبزن خارج از تجزیه‌گر استفاده شده و در سناریوی سوم برچسب معیار واژه‌ها برای تجزیه جملات مورد استفاده قرار گرفته‌اند. نتایج عملی نشان داد که کیفیت برچسب مقولات دستوری بر کارآیی تجزیه‌گر تأثیر دارد. همچنین با انجام آزمایش‌ها برای بررسی تأثیرگذاری میزان اطلاعات از نظر دانه‌درشتی یا دانه‌ریزی این نتیجه به دست آمد که اطلاعات بیشتر درمورد ویژگی‌های صرفی-نحوی هر واژه بر کارآیی تجزیه‌گر تأثیر مثبت دارد؛ و این تأثیرگذاری نسبت به کیفیت برچسب مقولات دستوری خیلی بیشتر است.

7-references

۷-مراجع

[۱] م. بی جن خان, ”نقش پیکره زبانی در نوشتمن دستور زبان: معرفی یک نرم‌افزار رایانه‌ای“, *مجله زبانشناسی*, ج. ۸, صص. ۶۷-۴۸.

M. Bijankhan, “naqše peykarehāye zabāni dar neveštane yek narmafzāre rāyāneyi [The role of corpora in writing a grammar: Introducing a software],” *Iranian Journal of Linguistics*, vol. 38, pp.46-67, 2004.

[۲] م. شریفی آتشگاه, ”تولید نیمه‌خودکار درخت‌بانک گروههای نحوی در زبان فارسی معاصر“, پایان‌نامه دکترا، دانشکده ادبیات و علوم انسانی، دانشگاه تهران، ۱۳۸۸.

M. SharifiAtashgah, “toulide nimexodkāre deraxtbānke goruhāye nahvi dar zabāne fārsi [Semi-automatic Generation of Treebanks in Persian Texts]”, PhD dissertation, University of Tehran, 2009.

[۳] م.ب. صادق‌زاده، و همکاران, ”بررسی روش‌های مؤثر بر عملکرد تجزیه‌گر آماری زبان فارسی“, سومین همایش ملی زبان‌شناسی رایانشی، تهران، دانشگاه شریف، ۱۳۹۳.

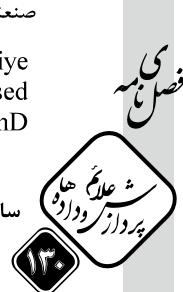
M.B. Sadeghzade *et al.*, “barresiye ravešhāye mo’asser bar ‘amalkerde tažiyegare ‘āmāriye zabāne fārsi [Study the impact of effecting methods on the performance of a statistical parser for the Persian language],” In *Proceedings of the 3rd National Conference on Computational Linguistics*, Sharif University of Technology, Tehran, 2014.

[۴] م. عاصی, ”پایگاه داده زبان فارسی“, پژوهشگاه علوم انسانی و مطالعات فرهنگی, تهران, ۱۳۸۴.

M. Assi, “PLDB: The Persian Linguistics DataBase,” In *Researchers*, Institute for Humanities and Cultural Studies, Tehran, Iran, 2005.

[۵] ه. فیلی, ”استخراج استقرایی گرامر احتمالاتی یک زبان طبیعی به روش بی‌مربی“, پایان‌نامه دکترا، دانشکده مهندسی کامپیوترا، دانشگاه صنعتی شریف، ۱۳۸۵.

H. Faili, “estextrāje esteqrāyiye gerāmere ehtemālatiye yek zabāne tabi'i be raveše bimorabbi [Unsupervised Grammar Induction for a Natural Language]”, PhD





International Symposium on Signal Processing and its Applications, Sharjah, (U.A.E.), 2007.

- [42] K. Toutanova and C.D. Manning, “Enriching the knowledge sources used in a maximum entropy part-of-speech tagger,” In *Proceedings of the Joint SIGDAT Conference on EMNLP and Very Large Corpora*, Hong Kong, pp. 63–70, 2000.



مسعود قیومی عضو هیأت علمی پژوهشگاه علوم انسانی و مطالعات فرهنگی است. وی فارغ‌التحصیل مقطع دکترا رایانه با گرایش زبان‌شناسی رایانشی در سال ۲۰۱۴ از دانشگاه آزاد برلین آلمان است. وی در سال ۲۰۰۹ از دانشگاه سارلند آلمان و در سال ۲۰۰۸ از دانشگاه نانسی ۲ فرانسه موفق به اخذ مدرک کارشناسی ارشد در رشته زبان‌شناسی رایانشی شد. همچنین وی در سال ۱۳۸۳ دوره کارشناسی ارشد خود را در رشته زبان‌شناسی همگانی در دانشگاه آزاد واحد تهران مرکز به پایان رساند. ایشان در سال ۱۳۸۰ در رشته مترجمی زبان انگلیسی از دانشگاه آزاد اسلامی قم فارغ‌التحصیل شد. زمینه‌های تخصصی مورد علاقه ایشان پردازش زبان طبیعی، مدل‌سازی زبانی، یادگیری ماشین، نحو و معناشناسی واژگانی است.

نشانی رایانمۀ ایشان عبارت است از:
masood.ghayoomi@gmail.com

