



Razi University



Automatic Recognition of Authors Identity in Persian Based on Systemic Functional Grammar

Fatemeh Soltanzadeh^{ID1}, Azadeh Mirzaei^{ID2}, Mohammad Bahrani^{ID3}, and Shahram Modarres Khiabani^{ID4}

1. Corresponding Author, Ph.D. in Linguistics, Department of Linguistics, Faculty of Persian Literature and Foreign Languages, Allameh Tabataba'i University, Tehran, Iran. E-mail: fatemeh.slt@gmail.com
2. Associate Professor of Linguistics, Department of Linguistics, Faculty of Persian Literature and Foreign Languages, Allameh Tabataba'i University, Tehran, Iran. E-mail: azadeh.mirzaei@atu.ac.ir
3. Assistant Professor, Department of Computer, Faculty of Statistics, Mathematics and Computer, Allameh Tabataba'i University, Tehran, Iran. E-mail: bahrani@atu.ac.ir
4. Assistant Professor, Department of English Language and Translation, Islamic Azad University, Karaj, Iran. E-mail: shmodarress@yahoo.com

Article Info

ABSTRACT

Article type:
Research Article

Article history

Received: 19 Jul 2023

Received in revised form: 20 Sep 2023

Accepted: 23 Sep 2023

Published online: 22 Sep 2024

Keywords:

author identification,
forensic linguistics,
systemic functional
grammar, function words,
conjunctive adjunct,
mood adjunct,
comment adjunct.

Automated author identification is one of the important fields in forensic linguistics. In this study, the effectiveness of systemic functional grammar (Halliday & Matthiessen, 2014) features in Persian authorship attribution was compared with that of function words. First, a corpus composed of documents written by seven contemporary Iranian authors was collected. Second, a list of function words was extracted from the corpus. Moreover, conjunction, modality and comment adjunct system networks were applied to form a lexicon using linguistics resources. Then, the relative frequency of function words in addition to systemic functional features were calculated in each document. Multilayer perceptron classifier, a type of neural network, was used for learning phase which resulted in a desirable accuracy in evaluation phase. The results of the study showed that using function words method is superior to systemic functional approach alone in Persian author identification, however, simultaneous use of the two methods increases the effectiveness in comparison to each alone.

Cite this article: Soltanzadeh, F., Mirzaei, A., Bahrani, M., & Modarres Khiabani, Sh. (2024). Automatic recognition of authors identity in Persian based on systemic functional grammar. *Research in Western Iranian Languages and Dialects*, 12(3), 59-84. <http://doi.org/10.22126/jlw.2023.9391.1716> (in Persian).



© The Author(s).

DOI: <https://doi.org/10.22126/jlw.2023.9391.1716>

Publisher: Razi University

Introduction

Recently, automated author identification has become a key focus for forensic linguistics. Author identification involves determining the writer of a text from a set of potential authors. The text in question could be a threatening letter, an email, a literary work, or a scientific article or book. The basis for author identification rests on the idea that different authors may write about the same topic using overlapping, yet distinct, lexico-grammatical units—an issue referred to as idiolect (Coulthard, 2004).

The first significant attempt to identify writing styles was Mendenhall's study of Shakespeare's plays (1887). The play *Henry VIII* is widely recognized as a collaborative work, not solely authored by William Shakespeare. Plechac (2020) investigated the use of accent or stress to identify the contributions of other authors to the play.

In Persian, several studies have been conducted to determine authorship (Arefi et al., 2021; Farahmandpour et al., 2013). These studies utilized repetitive features, such as lexical richness, frequency of syntactic groups, collocations, and the relative frequency of punctuation marks, to detect writing styles. Measuring the frequency of function words is one valid method for author identification. Function words, which have limited meanings, indicate the functional relationships between components of a sentence. Golshaie (2019) and Dabagh (2007) applied the frequency of Persian function words to identify authors. This study aims to compare the efficacy of function word frequency with systemic functional grammar methods in automatically identifying writing styles.

Theoretical Framework

Systemic Functional Grammar (SFG) is a component of the social semiotic approach to language known as systemic functional linguistics (Halliday & Matthiessen, 2014). SFG conceptualizes language as a network of systems, or interrelated sets of options for creating meaning. Since the 1960s, SFG has been applied in various contexts within computational linguistics (Matthiessen & Bateman, 1991; Teich, 1995). In SFG, the clause is considered the fundamental unit of language, and it is analyzed through three perspectives, defined as the ideational, interpersonal, and textual metafunctions. The ideational function is further divided into the experiential and logical aspects (Halliday & Matthiessen, 2014).

This study employs three system networks: conjunction, modality, and comment. These networks correspond to three types of adjuncts: conjunctive adjuncts, mood adjuncts, and comment adjuncts, respectively. In the systemic environment of conjunction, conjunctions function as conjunctive adjuncts within the clause structure. They establish relationships where one segment of text elaborates on, extends, or enhances another segment (Halliday & Matthiessen, 2014).

Modal adjuncts express the speaker's or writer's judgment or attitude toward the content of the message. There are two types of modal adjuncts: (i) mood adjuncts and (ii) comment adjuncts. Mood adjuncts and comment adjuncts are categorized within the modality and comment adjunct system networks, respectively. Modality encompasses intermediate degrees between positive and negative poles, defining the region of uncertainty between 'yes' and 'no.' The modality system allows writers to qualify events or entities in terms of their probability, typicality, obligation, or inclination (Halliday & Matthiessen, 2014). The comment adjunct system provides a means for the writer to comment on the status of a message concerning the textual and interactive context of the discourse (Argamon et al., 2007). Comments can target either the ideational content of the proposition or the interpersonal aspects of the speech function (Halliday & Matthiessen, 2014).

Method

A corpus was compiled from the works of seven contemporary Persian writers: Hoshang Golshiri, Bozorg Alavi, Ahmad Mahmoud, Mahmoud Dolatabadi, Nader Ebrahimi, Jalal Al-e

Ahmad, and Gholamhossein Saedi, totaling 2,069,243 words. From this corpus, a list of 197 function words was extracted using the Term Frequency-Inverse Document Frequency (TF-IDF) technique. Conjunction, modality, and comment adjunct system networks were then used to create a lexicon.

An author identification system was designed using machine learning techniques. The system tokenized the texts, extracted instances of lexical units specified in the lexicon, and computed the relative frequencies of semantic attribute values for each text, resulting in an overall "feature vector" that described each text. This approach was inspired by the method introduced by Argamon et al. (2007). For the learning phase, a multilayer perceptron classifier, a type of neural network, was utilized.

Results

To evaluate the system, the collected corpus was divided into five segments, and a 5-fold cross-validation method was applied. The 5-fold cross-validation demonstrated a satisfactory accuracy when focusing exclusively on function words. The combined use of function words and SFG methods achieved an accuracy of 74.47% for Persian author identification. Subsequent feature selection identified the most effective features for the machine learning phase. The results indicated that the relative frequency of function words outperformed SFG-based attributes in terms of effectiveness.

Discussion and Conclusions

The evaluation phase revealed that the function words-based method outperformed the systemic functional grammar (SFG) approach in identifying authors. However, the simultaneous use of both methods improved effectiveness compared to using either method alone. The superior performance of the function words-based method may be attributed to the high frequency of function words and the author's unconscious control over their use.

Among the SFG-based features, the combination of top features—namely conjunctive, mood, and comment adjuncts—produced higher accuracy than any single system network alone. Additionally, the results from feature selection indicated that features derived from the modality system network were more effective than those from the conjunction and comment adjunct system networks for Persian author identification.

Overall, while the function words-based method proved to be highly effective on its own, integrating it with SFG-based methods provided a more comprehensive approach, enhancing the accuracy of author identification.



انجمن زبان‌شناسی ایران

مطالعات زبان‌ها و گویش‌های غرب ایران

شابا جاپی: ۲۵۷۹ - ۲۳۴۵ شابا الکترونیکی: ۵۷۳۶ - ۲۶۷۶



تشخیص خودکار هویت نویسنده متن در زبان فارسی براساس دستور نقش‌گرای نظاممند

فاطمه سلطان‌زاده^۱ | آزاده میرزایی^۲ | محمد بحرانی^۳ | شهرام مدرس خیابانی^۴

۱. نویسنده مسئول، دکتری زبان‌شناسی، گروه زبان‌شناسی، دانشکده ادبیات فارسی و زبان‌های خارجه، دانشگاه علامه طباطبائی، تهران، ایران. رایانه: fatemeh.slt@gmail.com

۲. دانشیار گروه زبان‌شناسی، دانشکده ادبیات فارسی و زبان‌های خارجه، دانشگاه علامه طباطبائی، تهران، ایران. رایانه: azadeh.mirzaei@atu.ac.ir

۳. استادیار گروه رایانه، دانشکده آمار، ریاضی و رایانه، دانشگاه علامه طباطبائی، تهران، ایران. رایانه: bahrani@atu.ac.ir

۴. استادیار گروه آموزش مترجمی زبان انگلیسی، واحد کرج، دانشگاه آزاد اسلامی، کرج، ایران. رایانه: shmodarress@yahoo.com

اطلاعات مقاله

چکیده

تشخیص خودکار هویت نویسنده متن یکی از مسائل مهم زبان‌شناسی حقوقی تلقی می‌شود. در پژوهش حاضر تلاش می‌شود کارایی ویژگی‌های مبتنی بر مفاهیم دستور نقش‌گرای نظاممند هالیدی (هالیدی و متین، ۲۰۱۴) با کارایی واژه‌های دستوری در تشخیص هویت نویسنده مقایسه شود. به این منظور، در انتهای پیکره‌های از آثار هفت نویسنده معاصر ایرانی گردآوری شد. در مرحله دوم، از واژه‌های دستوری استخراج شده از پیکره فهرستی تهیه شد؛ به علاوه، یک مجموعه واژگان براساس شبکه نظام حروف ربط، شبکه نظام افزوده وجه و شبکه نظام افزوده نگرشی با استفاده از منابع زبانی تهیه شد. سپس بسامد نسبی واژه‌های دستوری و ویژگی‌های مبتنی بر دستور نقش‌گرای نظاممند در هر متن محاسبه شد. طبقه‌بند پرسپترون چند لایه، نوعی شبکه حسابی، برای مرحله آموزش سامانه به کار گرفته شد و به دقت مطابقی در مرحله ارزیابی منجر شد. بررسی نتایج ارزیابی سامانه نشان داد که روش محاسبه بسامد واژه‌های دستوری نسبت به روش مبتنی بر دستور نقش‌گرای نظاممند در تشخیص هویت نویسنده متن فارسی برتری دارد؛ باوجوداین، هنگامی که ویژگی‌های دستور نقش‌گرای نظاممند هالیدی در کار ویژگی بسامد واژه‌های دستوری به کار روند، کارایی سامانه نسبت به حالتی که تنها از ویژگی بسامد واژه‌های دستوری استفاده شود، ارتقا می‌یابد.

نوع مقاله: پژوهشی

تاریخ دریافت: ۱۴۰۲/۴/۲۸

تاریخ بازنگری: ۱۴۰۲/۶/۲۹

تاریخ پذیرش: ۱۴۰۲/۷/۱

تاریخ انتشار: ۱۴۰۳/۷/۱

کلیدواژه‌ها:

تشخیص هویت نویسنده،

زبان‌شناسی حقوقی،

دستور نقش‌گرای نظاممند، واژه‌های

دستوری،

افزوده ربطی،

افزوده وجه،

افزوده نگرشی.

استناد: سلطان‌زاده، فاطمه؛ میرزایی، آزاده؛ بحرانی، محمد؛ مدرس خیابانی، شهرام (۱۴۰۳). تشخیص خودکار هویت نویسنده متن در زبان فارسی براساس دستور نقش‌گرای نظاممند. *مطالعات زبان‌ها و گویش‌های غرب ایران*, ۱۲(۲)، ۵۹-۸۴. <https://doi.org/10.22126/jlw.2023.9391.1716>

ناشر: دانشگاه رازی

© نویسنده‌گان

DOI: <https://doi.org/10.22126/jlw.2023.9391.1716>



۱- مقدمه

در جهان امروز با توجه به پیشرفت فناوری و استفاده گسترده از شبکه جهانی وب^۱، این امکان برای کاربران فراهم است که در فضای مجازی هویت واقعی خود را پنهان سازند، با هویت جعلی خود را معرفی کنند، رایانه‌هایی بدون نام نویسنده واقعی بفرستند و حتی به سرقت ادبی یا علمی دست بزنند. ازین‌رو، لازم است سامانه‌های طراحی شوند که امنیت فضای مجازی را تأمین کنند، سرقت ادبی و علمی را کشف نمایند و به صورت خودکار هویت واقعی نویسندگان متون را در این فضا شناسایی کنند. به‌این‌علت، در دهه‌های اخیر تشخیص خودکار هویت نویسنده متن^۲ به یکی از مسائل مهم در زبان‌شناسی حقوقی^۳ تبدیل شده است.

تشخیص خودکار هویت نویسنده متن بر این فرض استوار است که هر فرد یک گویش فردی^۴ یا سبک خاص و منحصر به‌فرد در گفتار یا نوشتار دارد. درواقع، هنگامی که مردم از زبان استفاده می‌کنند، ساختهای خاصی از واژگان-دستور^۵ را برمی‌گزینند که دیگر افراد ممکن است از آن‌ها کمتر استفاده کنند. در مرحله بعد هر فرد این ساختهای را به شکلی متفاوت از دیگر افراد ترکیب می‌کند تا پیام خود را منتقل کند و این به معنای منحصر به‌فرد بودن گویش فردی و سبک گفتار یا نوشتار افراد است (کلتارد، ۲۰۰۴).

در زبان فارسی درباره تشخیص هویت نویسنده متن، پژوهش‌هایی مانند فرهمندپور و دیگران (۱۳۹۱) و عارفی و دیگران (۱۴۰۰) انجام شده است. در این پژوهش‌ها بیشتر جنبه‌های فنی و مهندسی کار مدنظر بوده و به جنبه‌های زبانی و نظری کمتر توجه شده است. در پژوهش‌های یادشده عمدتاً از ویژگی‌های تکراری (غنای واژگانی^۶، بسامد گروههای نحوی^۷، باهم‌آیی کلمات^۸، بسامد نسبی علائم نگارشی^۹) برای طراحی سامانه‌های تشخیص خودکار هویت نویسنده متن استفاده شده است و به طراحی ویژگی‌های زبانی برمنای یک نظریه زبانی خاص پرداخته نشده است. در زبان فارسی همچنین دو پژوهش دیگران (۱۳۹۸) و گلشاهی (۲۰۰۷) درخصوص تشخیص خودکار هویت نویسنده متن انجام شده است که ناظر بر جنبه‌های زبانی هستند. در این پژوهش‌ها از روش محاسبه بسامد واژه‌های دستوری^{۱۰} در تشخیص هویت نویسنده متن استفاده شده است. محاسبه بسامد واژه‌های دستوری یک روش مهم و معتبر در تشخیص هویت نویسنده است. از آنجاکه نویسنده در به کارگیری واژه‌های دستوری، کنترل خودآگاه ندارد و این واژه‌ها در متن به تعداد زیاد به کار می‌روند، آن‌ها می‌توانند ویژگی‌های منحصر به‌فردی در تشخیص خودکار نویسنده تلقی شوند (سگارا، ۲۰۱۵؛ دیگران، ۱۳۹۸).

دیگر^{۱۱} براساس واژه‌های دستوری پرسامد و با روش‌های آماری به جداسازی سبک نگارش نظامی گنجوی/شهریار و عبدالحسین زرین‌کوب/سیمین دانشور پرداخته است. نتایج این پژوهش نشان می‌دهد که به کمک واژه‌های دستوری می‌توان سبک نویسنده‌ها در نظم و نثر فارسی را مشخص کرد. گلشاهی (۱۳۹۸) باتکیه بر گویش فردی و با استفاده از واژه‌های دستوری زبان فارسی، تشخیص هویت نویسنده متن را برای پنج نویسنده معاصر بررسی کرده است. نتایج این پژوهش نشان می‌دهد که نویسنده‌های مختلف واژه‌های دستوری را به‌طور مشابه به کار نمی‌گیرند. درواقع، اگرچه همه نویسنده‌ها، برخی واژه‌های دستوری پرسامد را به کار می‌برند، اولویت نویسنده‌گان در به کارگیری آن‌ها متفاوت است.

پژوهشگران دو پژوهش نامبرده (دیگران، ۱۳۹۸؛ گلشاهی، ۲۰۰۷) اثبات می‌کنند که واژه‌های دستوری در نثر فارسی توانایی جداسازی سبک نویسنده‌گان را دارند؛ اما آن‌ها برای واژه‌های دستوری، دسته‌بندی معنایی^{۱۲} ارائه نمی‌کنند. دیگر^{۱۳} در انتخاب واژه‌های دستوری صرفاً به معیار پرسامد بودن واژه‌های دستوری بسته کرده است. گلشاهی (۱۳۹۸) نیز حداقل کلمات موردنیاز برای جداسازی

1. World Wide Web

2. author identification

3. forensic linguistics

4. ideolect

5. lexicogrammar

6. M. Coulthard

7. lexical richness

8. frequency of syntactic groups

9. collocation

10. relative frequency of punctuation marks

11. function words

12. S. Segarra

13. semantic classification

سبک نویسنده‌گان براساس واژه‌های دستوری را بررسی کرده است. وی توالی‌های یک تا سه‌واژه‌ای (تکنگاشتی^۱، دونگاشتی^۲، سه‌نگاشتی^۳) واژه‌های دستوری را در تشخیص هویت نویسنده متن ارزیابی کرده و درنهایت، واژه‌های تکنگاشتی یا همان واژه‌های دستوری تک‌واژه‌ای را کاراترین نوع واژه‌های دستوری در نظر گرفته است. علاوه براین، در پژوهش وی، گستره مفهوم واژه‌های دستوری، اندکی محدود شده و ضمایر و تمامی افعال (ربطی و غیرربطی) حذف شده است.

باتوجه به نکته‌های یادشده در بررسی نقش واژه‌های دستوری زبان فارسی در جداسازی سبک نویسنده‌گان، نیاز است در انتخاب واژه‌های دستوری به مؤلفه‌های معنایی بیشتر توجه شود و برای آن‌ها دسته‌های معنایی ارائه شود. درنهایت، می‌توان انواع مختلف واژه‌های دستوری را آزمود و بهترین ترکیب واژه‌های دستوری را ازاین‌بین انتخاب کرد. در پژوهش حاضر تلاش می‌شود که این خلاصه در حوزهٔ تشخیص هویت نویسنده متن فارسی پُر شود و برای واژه‌های دستوری، دسته‌بندی معنایی ارائه شود. علاوه براین، کارایی سامانهٔ تشخیص هویت نویسنده با واژه‌های دستوری، مبنای مقایسه قرار گیرد و یک نظریهٔ معتبر معنایی در تشخیص سبک نویسنده زبان فارسی آزموده شود. همچنین به نظر می‌رسد طراحی ویژگی‌های زبانی جدید که مبتنی بر یک نظریهٔ زبانی معتبر باشد، درکنار واژه‌های دستوری، در ارتقای کارایی سامانه‌های تشخیص هویت نویسنده مؤثر باشد. بنابراین، تشخیص خودکار نویسنده متن برای زبان فارسی، مبتنی بر یک نظریهٔ زبانی معتبر با استفاده از ویژگی‌های زبانی جدید، یک ضرورت برای زبان فارسی در جهان پیچیده امروز محسوب می‌شود. دراین‌زمینه، در پژوهش حاضر تلاش بر آن است تا به کمک ویژگی‌های زبانی مبتنی بر دستور نقش‌گرای نظاممند^۴ هالیدی^۵ (هالیدی و متیسن^۶، ۲۰۱۴)، هویت نویسنده متن به صورت خودکار تشخیص داده شود و تأثیر ویژگی‌های دستور نقش‌گرا در مقایسه با ویژگی بسامد واژه‌های دستوری سنجیده شود.

پرسش‌های پژوهش حاضر عبارت از: ۱. کدام‌یک از ویژگی‌های زبانی مبتنی بر دستور نقش‌گرای نظاممند هالیدی (هالیدی و متیسن، ۲۰۱۴) بر تشخیص سبک نویسنده‌گان فارسی زبان تأثیرگذار است؟ ۲. اگر ویژگی‌های زبانی مبتنی بر دستور نقش‌گرای نظاممند هالیدی (هالیدی و متیسن، ۲۰۱۴) درکنار ویژگی بسامد واژه‌های دستوری به کار روند، بر کارایی سامانه نسبت به حالتی که تنها از ویژگی بسامد واژه‌های دستوری استفاده شود، چه تأثیری دارد؟

برای تشخیص خودکار نویسنده متن از ویژگی‌های زبانی در سطوح مختلف همچون ویژگی‌های آوابی^۷، واژگانی، نحوی، معنایی و ترکیب آن‌ها استفاده می‌شود. پس از تعریف ویژگی‌ها، اسناد موجود در پیکره که هر کدام به یک نویسنده خاص در یک مجموعهٔ بسته تعلق دارند، با بهره‌گیری از ویژگی‌های زبانی تعریف شده به روش یادگیری ماشین دسته‌بندی و اسناد مشابه به یک نویسنده واحد منسوب می‌گردد.

نخستین تلاش برای سنجیدن سبک نگارش به سده نوزدهم میلادی و بررسی نمایشنامه‌های شکسپیر^۸ باز می‌گردد (مندنhal، ۱۸۸۷). این پرسش که آیا شکسپیر تمام آثارش را خود به تنهایی نوشته است، سال‌ها برای پژوهشگران بحث‌برانگیز بوده است. برای مثال، برخی معتقدان ادبی معتقد بودند که شکسپیر نمایشنامهٔ هنری هشتم^۹ را به کمک فرد دیگری نوشته است. پژوهشگران رایانه و هوش مصنوعی این ادعا را سال‌ها بررسی کرده و درنهایت، به این نتیجه رسیده‌اند که وی با همکاری فردی به نام فلچر^{۱۰} نمایشنامهٔ هنری هشتم را نوشته است (پلچاک^{۱۱}، ۲۰۲۱). این کار با تکیه بر ویژگی‌های آوابی و الگوهای غالب آهنگین^{۱۲} (توزیع هجاهای تکیدار و بدون تکیه در یک سطر) انجام شده است.

از شمارش کلمات پرترکار، میانگین طول واژه‌ها در متن و تعداد تکرار کلمات منحصر به فرد و غنای واژگانی نیز به منزلهٔ ویژگی‌های

1. unigram
2. bigram
3. trigram
4. systemic functional grammar (SFG)
5. M. A. K. Halliday
6. C. M. M. Matthiessen
7. phonetic
8. W. Shakespeare
9. T. C. Mandenhal
10. Henry VIII
11. J. Fletcher
12. P. Plecháč
13. rhythmic

واژگانی برای تشخیص خودکار نویسنده استفاده می‌شود (استاماتاتوس^۱، ۲۰۰۹). در برخی پژوهش‌ها از ترکیب چند نوع ویژگی بهره گرفته شده است. برای مثال، در پژوهش ویراسینگه^۲ و دیگران (۲۰۲۱)، ویژگی بسامد واژه‌های دستوری، بسامد گروههای نحوی و غنای واژگانی به کار گرفته شده است. نجفی و تاوان (۲۰۲۲) که از بسامد گروههای نحوی، موجودیت‌های نامدار^۳ و باهم‌آیی کلمات در کنار یادگیری عمیق^۴ بهره می‌گیرند به کارایی مطلوبی در تعیین هویت نویسنده در زبان انگلیسی دست می‌یابند. مارتینز^۵ و دیگران (۲۰۲۲) نیز ویژگی بسامد گروههای نحوی را با روش شبکه عصبی گرافی^۶ می‌آزمایند و به دقت مناسبی دست می‌یابند.

دو پژوهش آرگامون^۷ و دیگران (۲۰۰۷) و آرگامون و کوپل^۸ (۲۰۱۳) نیز برای تشخیص خودکار نویسنده متن در زبان انگلیسی انجام شده است؛ در این پژوهش‌ها از مجموعه‌ای از ویژگی‌ها که براساس دستور نقش‌گرای نظاممند هالیدی (هالیدی و متیسن، ۲۰۱۴) نظام یافته‌اند، بهره گرفته شده است. در پژوهش آرگامون و دیگران (۲۰۰۷)، از دستور نقش‌گرای نظاممند در تشخیص هویت، جنسیت^۹، ردۀ سنی و ملیت نویسنده متن استفاده شده و کارایی این دستور در مقایسه با بسامد واژه‌های دستوری سنجیده شده است. در پژوهش آرگامون و کوپل (۲۰۱۳)، از این دستور برای تشخیص جنسیت، ردۀ سنی، ملیت و ویژگی‌های شخصیتی^{۱۰} نویسنده استفاده شده و کارایی این دستور در مقایسه با واژه‌های محتوایی^{۱۱} مقایسه شده است. به این منظور، یک واژگان خاص طراحی شده است که کلمات و عباراتی را دربرمی‌گیرد که از شبکه واژگان و اصطلاح‌نامه‌های^{۱۲} برخط گردآوری شده است. هر مدخل واژگان ویژگی‌هایی دارد که برگرفته از دستور نقش‌گرای نظاممند است. نتایج پژوهش آرگامون و دیگران (۲۰۰۷) نشان می‌دهد که این ویژگی‌ها در ترکیب با ویژگی‌های مبتنی بر واژه‌های دستوری بیشترین کارایی را دارند. پژوهش آرگامون و کوپل (۲۰۱۳) نیز بیانگر آن است که در تشخیص جنسیت، ردۀ سنی و ملیت نویسنده متن در زبان انگلیسی کارایی پایین‌تری در تشخیص جنسیت، ردۀ سنی و ملیت نویسنده متن در زبان انگلیسی داشته است.

۲- مبانی نظری

۱-۲ دستور نقش‌گرای نظاممند

در پژوهش حاضر، از مفاهیم دستور نقش‌گرای نظاممند هالیدی (هالیدی و متیسن، ۲۰۱۴) برای تشخیص خودکار هویت نویسنده متن استفاده می‌شود. این دستور، زبان‌ها را به‌منزله نظامی از انتخاب‌ها برای بیان معنا‌گویانی و همه انتخاب‌های ساختاری و واژگانی را براساس نقش‌های معنایی آن‌ها بازنمایی می‌کند. این نظریه در پردازش زبان طبیعی^{۱۳} و زبان‌شناسی رایانشی از دهه ۱۹۶۰ میلادی به کار گرفته شده است؛ بهویژه اینکه در تولید متن^{۱۴} بسیار کاربرد دارد (تیچ^{۱۵}، ۱۹۹۵؛ متیسن و بتمن^{۱۶}، ۱۹۹۱). دستور نقش‌گرای نظاممند هالیدی مجموعه‌ای از محدودیت‌ها را در بیان معنا تعریف می‌کند. این دستور شبکه‌ای از گرینه‌های محتمل است. این شبکه از انتخاب‌ها، شبکه نظام^{۱۷} نامیده می‌شود. با داشتن این شبکه می‌توان برای توصیف سبک یک متن از ویژگی‌های آماری بهره برد؛ به این شکل که بسامد شرطی هر گره^{۱۸} را در این شبکه با داشتن گره والد^{۱۹} آن محاسبه کرد و آن را معیاری برای توصیف سبک متن به کار

1. E. Stamatatos
2. J. Weerasinghe
3. named entities
4. deep learning
5. J. A. Martinez-Galicia
6. graph neural networks
7. S. Argamon
8. M. Koppel
9. gender
10. personality
11. content words
12. thesaurus
13. natural language processing
14. text generation
15. E. Teich
16. J. A. Bateman
17. system network
18. node
19. parent node

برد. این تفسیر بر این اصل استوار است که نویسنده دارای سبک خاص و منحصر به فرد، برای بیان معنا گزینه‌های خاصی را بر دیگر گزینه‌ها ترجیح می‌دهد (آرگامون و دیگران، ۲۰۰۷). بنابراین، در پژوهش حاضر، از دستور نقش‌گرای نظاممند هالیدی برای چارچوب نظری پژوهش و از روش پیشنهادی در پژوهش آرگامون و دیگران (۲۰۰۷) برای تعریف ویژگی‌ها در تشخیص هویت نویسنده استفاده می‌شود.

زبان در دستور نقش‌گرای نظاممند به صورت نظامی از معناها در نظر گرفته می‌شود که با صورت^۱ همراه می‌شود. واحد مطالعه در دستور نقش‌گرای نظاممند بند^۲ است. از لحاظ معنایی، بند سه لایه مستقل دارد که باهم در تعامل هستند. این لایه‌ها فرانش^۳ نامیده می‌شوند و عبارت‌اند از: ۱. فرانش تجربی^۴ که تجربه نویسنده از هستی را بازنمایی می‌کند. ۲. فرانش بینافردی^۵ که به نحوه تعامل میان شرکت‌کنندگان در یک رویداد گفتمانی می‌پردازد. ۳. فرانش متنی^۶ که انسجام و پیوستگی میان مطالب را در یک متن سامان می‌دهد (هالیدی و متیسن، ۲۰۱۴).

در پژوهش پیش‌رو، افزوده‌ها^۷ در دو فرانش بینافردی و متنی مدنظر هستند. در این پژوهش، افزوده ربطی^۸ که در فرانش متنی مطرح است و افزوده وجهی^۹ (افزوده وجه^{۱۰} و افزوده نگرشی^{۱۱}) که در فرانش بینافردی به کار می‌رود، برای تشخیص هویت نویسنده استفاده می‌شود. در این زمینه، سه نوع شبکه نظام معرفی می‌شود: شبکه نظام حروف ربط^{۱۲}، شبکه نظام وجهنمایی^{۱۳} و شبکه نظام افزوده نگرشی. در ابتدا، درباره فرانش متنی و شبکه نظام حروف ربط بحث می‌شود. سپس به فرانش بینافردی و دو نوع شبکه نظام وجهنمایی و شبکه نظام افزوده نگرشی پرداخته می‌شود.

۱-۱-۲ فرانش متنی

در فرانش متنی نحوه چینش سازه‌ها با عنوان ساخت آغازگری-پایان‌بخشی^{۱۴} بررسی می‌شود. آغازگر بهمنزله نقطه عزیمت پیام، نخستین سازه بند است به شرط آنکه مشارک^{۱۵}، فرایند^{۱۶} یا افزوده حاشیه‌ای باشد (هالیدی و متیسن، ۲۰۱۴). بقیه جمله‌منهای آغازگر، پایان‌بخش است.

افزوده‌های ربطی (حروف ربط) در فرانش متنی مطرح هستند و بین دو بند یا دو جمله پیوند منطقی برقرار می‌کنند. جایگاه بی‌نشان آن‌ها در ابتدای بند یا پس از آغازگر است. این افزوده‌ها که با انسجام متن مرتبط هستند، در دستور نقش‌گرای نظاممند در شبکه نظام حروف ربط سازمان‌بندی می‌شوند. انواع مختلف حروف ربط برای پیونددادن بندها به کار گرفته می‌شوند. حروف ربط نشان می‌دهند که چگونه یک بند براساس بافت پیشین بسط و توسعه می‌باید. در این شبکه نظام، افزوده ربطی (حرف ربط) به سه دسته کلی افزوده تشریحی^{۱۷}، گسترشی^{۱۸} و تفصیلی^{۱۹} تقسیم می‌شود (هالیدی و متیسن، ۲۰۱۴) که در شکل (۱) مشاهده می‌شود.

در افزوده تشریحی، افزوده‌ها خود به دو دسته کلی تقسیم می‌شوند: بدلی^{۲۰} و واضح‌سازی^{۲۱}. در افزوده بدلی، یک عنصر دوباره معرفی یا

1. form
2. clause
3. metafunction
4. experiential metafunction
5. interpersonal metafunction
6. textual metafunction
7. adjunct
8. conjunctive adjunct
9. modal adjunct
10. mood adjunct
11. comment adjunct
12. conjunction
13. modality
14. theme-rheme
15. participant
16. process
17. elaborating
18. extending
19. enhancing
20. appositive
21. clarification

بیان می‌شود که به صورت توضیحی^۱ یا به صورت نمونه‌سازی^۲ است. در افزودهٔ واضح‌سازی نیز آن عنصر به شکل واضح‌تری بیان می‌شود.^۳ مثال‌های (۱) و (۲) به ترتیب نمونه‌ای از «افزودهٔ تشریحی، بدلي، توضیحی» و «افزودهٔ تشریحی، بدلي، نمونه‌سازی» هستند.

۱. آنچه به تو می‌گوییم یقین و حتمی است مثل این است که خودم از دهن صاحب‌کار شنیده باشم (علوی، ۱۳۸۶).

۲. ما مسلمانیم ارباب؛ مثالاً خود من تا حالا حتی یک بار هم نشده نماز قضا بشود (گلشیری، ۱۳۷۰).

افزودهٔ گسترشی خود به سه دسته کلی تقسیم می‌شود: ۱. افزودهٔ افزایشی^۴: چیزی را به معنا می‌افزاید. ۲. افزودهٔ تغییری^۵: به نوعی معنا را تغییر می‌دهد. ۳. افزودهٔ تباینی^۶: برخلاف آن چیزی را بیان می‌کند. در مثال (۳) و (۴) می‌توانید به ترتیب نمونه‌ای از «افزودهٔ گسترشی، افزایشی، مثبت»^۷ و «افزودهٔ گسترشی، تباینی» را مشاهده کنید.

۳. بچه‌ها هورا کشیدند و کف زدند (آل احمد، ۱۳۴۶).

۴. شب‌ها اگر از فرسنگ‌ها راه به جهت تپه‌ماهورهای شبانکاره نگاه می‌کردی، نور نارنجی پایداری می‌دیدی که بیش و کم می‌شد؛ اما مرگ نداشت (ابراهیمی، ۱۳۹۹).

افزودهٔ تفصیلی که پیوستگی^۸ را از طریق مقایسهٔ بین عناصر یا بندها به وجود می‌آورد خود به چهار دستهٔ کلی تقسیم می‌شود: مضمون^۹، شیوه^{۱۰}، فضایی-زمانی^{۱۱}، سببی-شرطی^{۱۲}. مثال‌های (۵) و (۶) نمونه‌هایی از «افزودهٔ تفصیلی، شیوه»^{۱۳}، طریق^{۱۴} هستند.

۵. یکی دو مرتبه که مردم ده بیچاره می‌شدند، کدخدا را پیش خان همسایه می‌فرستادند و از او کمک می‌گرفتند و بدین طریق دهکده‌ای به تصرف خانی درمی‌آمد (علوی، ۱۳۹۹).

۶. راه افتاد طرف در و پیش از اینکه خارج شود ایستاد و بعد با صدای محکمی پرسید: «برویانف را چطور کشته؟» (ساعدي، ۱۳۹۷).

مثال (۷) نمونه‌ای از «افزودهٔ تفصیلی، فضایی-زمانی، ساده، همزمانی» است که به لحاظ توالی زمانی، به دو رویداد همزمان اشاره دارد.

۷. خودت عاجز نکن ننه؛ حالا کی می‌خواهد بفروشه؟ (محمد، ۱۳۵۳).

افزودهٔ سببی-شرطی نیز از دو نوع کلی سببی و شرطی تشکیل شده است. افزودهٔ سببی خود به دو نوع عام^{۱۴} و مشخص^{۱۵} تقسیم می‌شود. در نوع «مشخص» افزوده به تبیجه^{۱۶}، علت^{۱۷} و قصد^{۱۸} اختصاص می‌باشد. در مثال (۸) و (۹) می‌توانید به ترتیب نمونه‌ای از «افزودهٔ سببی-شرطی، سببی، مشخص، علت» و «افزودهٔ سببی-شرطی، شرطی، منفی»^{۱۹} را مشاهده کنید.

۸. وکیل رعیت وفادارترین رعیت خویش را به هوسری به زنجیر کشید و کشان به بازار آورد و به دار مجازاتی که هیچ حقش نبود آویخت، فقط به‌خاطر آنکه خود را دربرابر اجانب کوچک‌تر از او می‌دید (ابراهیمی، ۱۳۹۹).

۹. با این حرف‌ها نمی‌خواهم ناراحتت کنم؛ اما تو باید بدانی، باید بفهمی، حتمًا کریستین برایت نگفته اگرنه کار به اینجاها نمی‌کشید (گلشیری، ۱۳۵۰).

همان‌گونه که پیش‌تر اشاره شد در شکل (۱) شبکه نظام حروف ربط هالیدی و متیسن (۲۰۱۴) مشاهده می‌شود که سه دستهٔ کلی

1. expository

2. exemplifying

۳. شایان ذکر است که افزودهٔ « واضح‌سازی» نیز خود به هفت زیربخش تقسیم می‌شود؛ به دلیل جزئیات زیاد، در این پژوهش این تقسیم‌بندی مورد توجه نبوده است و در شکل (۱) نمایش داده نشده است. همین مسئله درباره افزودهٔ «مرکب، فضایی-زمانی، تفصیلی» نیز صادق است.

4. additive

5. varying

6. adversative

۷. افزودهٔ افزایشی به دو صورت مثبت و منفی است.

8. cohesion

9. matter

10. manner

11. spatio-temporal

12. causal-conditional

۱۳. افزودهٔ شیوه، پیوستگی را به وسیله مقایسه یا ارجاع بین عناصر ایجاد می‌کند و به دو گروه افزودهٔ مقایسه‌ای و طریق تقسیم می‌شوند.

14. general

15. specific

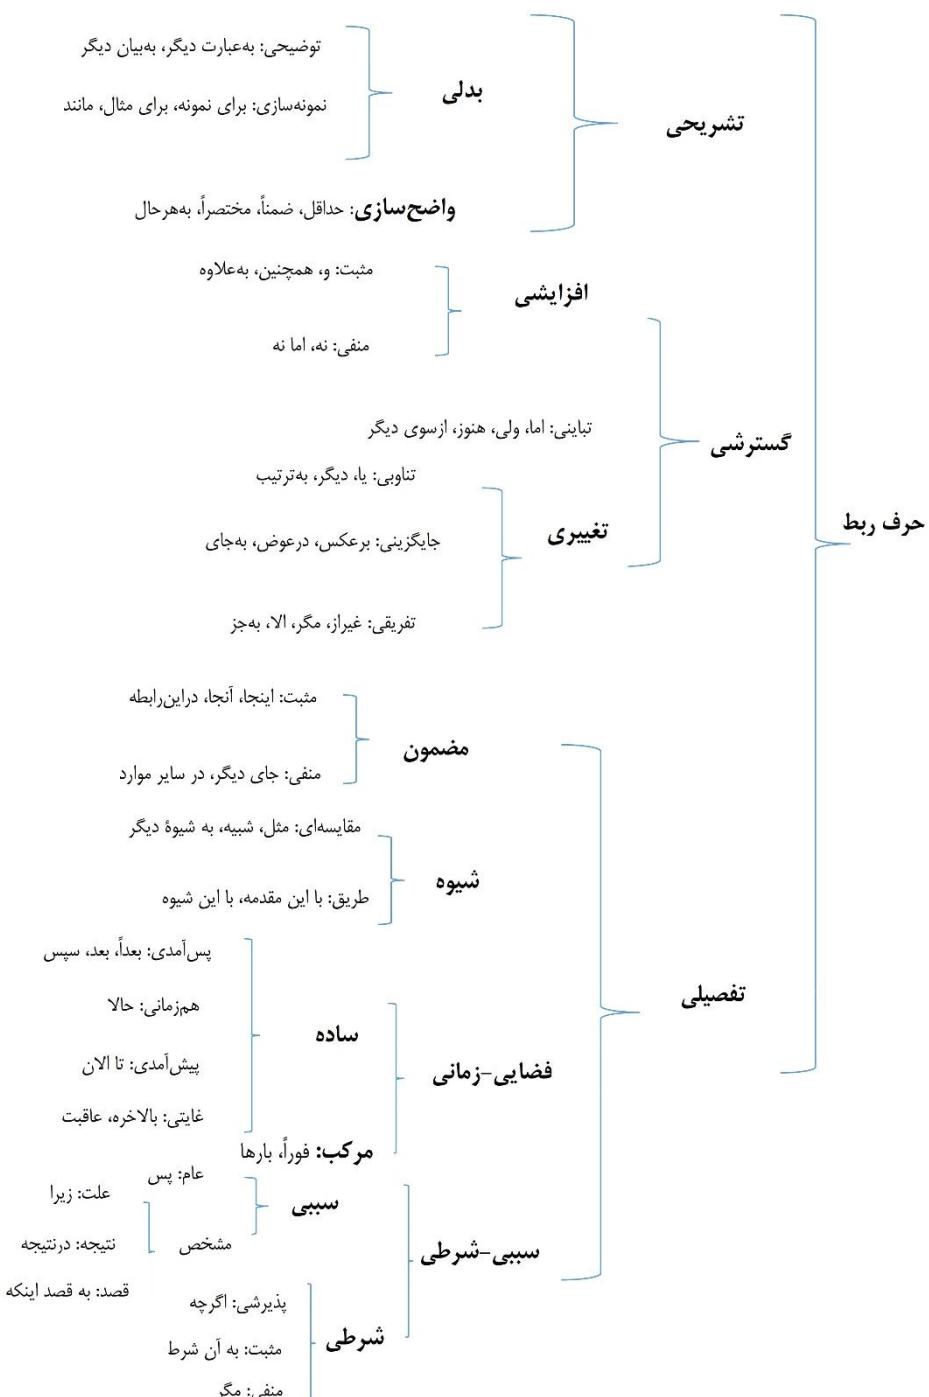
16. result

17. reason

18. purpose

۱۹. افزوده‌هایی همچون «مگر»، «اگرنه» و «در غیر این صورت» از نوع «افزودهٔ سببی-شرطی، شرطی، منفی» هستند.

افروزهٔ تشریحی، گسترشی و تفصیلی را شامل می‌شود.



شکل (۱). شبکهٔ نظام حروف ربط (جعفری، ۱۳۸۸: ۱۳۷-۱۳۹؛ هالیدی و متیسن، ۱۴۰؛ ۲۰۱۲)

۲-۱-۲ فرانش بینافردی

در فرانش بینافردی هر بند نوعی تبادل است. تعامل زبانی در این فرانش یک رابطه دادوستد کالا یا خدمات یا اطلاعات است. در واقع، در این فرانش پیام از نوع گزاره^۱ یا پیشنهاد^۲ است. در صورتِ دادن یا خواستن اطلاعات، پیام از نوع گزاره و در صورتِ عرضه یا درخواست کالا یا خدمات^۳ پیام از نوع پیشنهاد است (هالیدی و متیسن، ۲۰۱۴). گوینده در فرانش بینافردی ابزارهایی در دست

1. proposition
2. proposal
3. goods and services

دارد که با آن‌ها می‌تواند نظر خود را در پیام منعکس کند، میزان قطعیت^۱ گزاره را تخمین بزند یا سبب شود که احتمال اجرایی‌شدن پیشنهاد افزایش یابد. میزان قطعیت هر گزاره با صورت‌بندی‌هایی که نماینده مفهوم احتمال^۲ هستند (حتماً، احتمالاً، شاید، به‌احتمال زیاد، احتمال می‌رود و...)، همچنین با قیود تکرار (همیشه، اغلب، گاهی و...) مشخص می‌شود. میزان قطعیت یا بهبیان بهتر، ضمانت اجرایی پیشنهاد با صورت‌بندی‌هایی منتقل می‌شود که نماینده مفهوم اجبار یا التزام^۳ (اجبار، پیشنهاد و اجازه) و تمایل^۴ (تصمیم، توافقی و تمایل) هستند (میرزایی، ۱۳۹۷).

در این فرائقش محتوای یک بند به دو عنصر وجه^۵ و مانده^۶ تقسیم می‌شود. وجه آن بخش از بند است که از دو قسمت اصلی تشکیل شده است: ۱. فاعل^۷ که یک گروه اسمی است. ۲. عنصر زمان‌دار^۸ که بخشی از گروه فعلی است و بیانگر زمان، نمود^۹، وجه، جهت^{۱۰} و قطعیت^{۱۱} است. عنصر بعدی در سازمان‌بندی نقش‌ها در معنای بینافردی، مانده است که خود از سه عنصر نقشی مختلف تشکیل شده است: (الف) محمول^{۱۲}؛ (ب) متمم^{۱۳}؛ (ج) افزوده. محمول در تمام بندها با گروه فعلی تحقق می‌یابد. متمم آن قسمت از مانده است که فاعل نیست؛ ولی توافقی فاعل‌شدن را دارد و معمولاً به صورت گروه اسمی ظاهر می‌شود. افزوده، عنصری از مانده است که توافقی فاعل‌شدن را ندارد و به‌طور مشخص به صورت یک گروه قیدی یا حرف اضافه‌ای ظاهر می‌شود (جعفری، ۱۳۸۸: ۱۳۳).

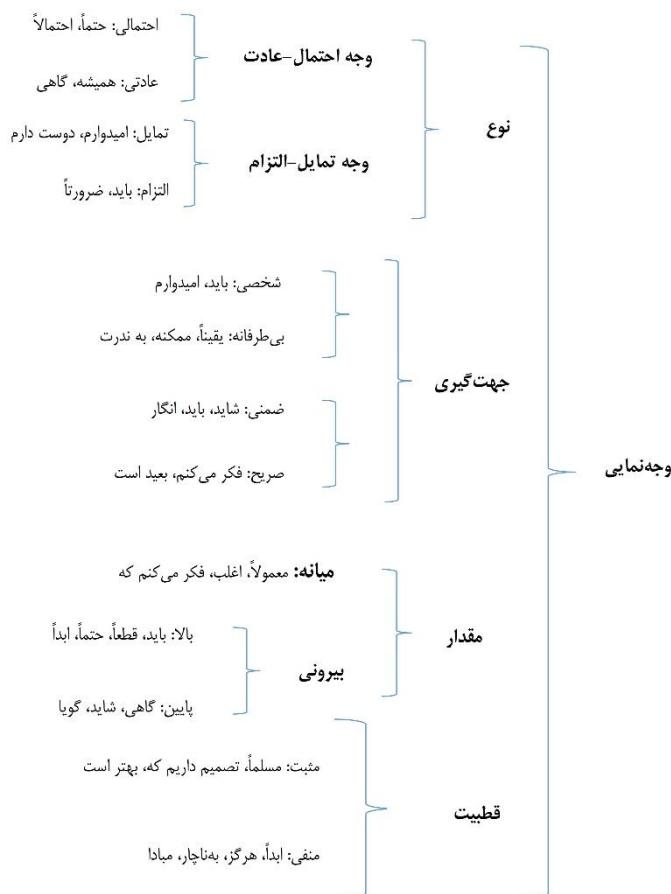
افزوده وجهی در فرائقش بینافردی مطرح است و خود به دو دسته تقسیم می‌شود: (الف) افزوده‌های وجه که مفاهیمی چون احتمال، اجبار^{۱۴} (التزام)، تمایل^{۱۵}، عادت^{۱۶}، شدت^{۱۷} و زمان را بیان می‌کنند. (ب) افزوده‌های نگرشی که تفسیر، قضاوت و اظهارنظر در مورد پیام و گزاره‌ای را که بیان می‌شود، ارائه می‌دهد. افزوده‌های وجه در شبکه نظام وجه‌نمایی جای می‌گیرند. آن‌ها نویسنده را قادر می‌سازند که حوادث و موجودیت‌ها را در متن براساس احتمال، عادت، تمایل و اجبار ارزش‌گذاری کنند. این شبکه نظام از چهار زیرنظام نوع^{۱۸}، جهت‌گیری^{۱۹}، مقدار^{۲۰} و قطعیت تشکیل شده است که در شکل (۲) سلسه‌مراتب آن نشان داده شده است.

زیرنظام نخست، «نوع» است که از دو نوع کلی وجه‌سازی^{۲۱} (وجه احتمال-عادت) و تعديل‌سازی^{۲۲} (وجه تمایل-التزام) تشکیل شده است. وجه‌سازی در ارتباط با گزاره موضوعیت می‌یابد. گزاره‌ها یا تأیید می‌شوند یا انکار. نقش نظام وجهیت تحلیل قلمرو عدم قطعیت مابین آری یا خیر است (حسین حمه و دیگران، ۱۴۰۰؛ هالیدی و متیسن، ۲۰۱۴). در وجه احتمال-عادت، از یکسو، احتمال وقوع گزاره مطرح است (قطعاً، احتمالاً، شاید، بعیده، غیرممکنه) و از سوی دیگر، میزان تکرار وقوع گزاره (همیشه، معمولاً، گاهی، هرگز). در مورد اول، وجه احتمال-عادت از نوع احتمالی و دومی از نوع عادتی است. تعديل‌سازی در ارتباط با پیشنهاد مطرح می‌شود. همان‌طور که پیش‌تر اشاره شد، میزان قطعیت پیشنهاد با صورت‌بندی‌هایی که نماینده مفهوم اجبار یا التزام (اجبار، پیشنهاد و اجازه) و تمایل (تصمیم، توافقی و تمایل) هستند، منتقل می‌شود. پس در تعديل‌سازی نیز دو نوع وجهیت مطرح است: وجه التزامی (مانند باید، ضرورتاً، قهرآ و...) و وجه تمایلی (مانند می‌خواهم، دوست داریم، تصمیم داریم و...).

همان‌طور که پیش‌تر گفته شد شبکه افزوده وجه از چهار زیرنظام نوع، جهت‌گیری، مقدار و قطعیت تشکیل شده است که در شکل

1. certainty
2. probability
3. obligation
4. inclination or readiness
5. mood element
6. residue
7. subject
8. finite
9. aspect
10. voice
11. polarity
12. predicator
13. complement
14. obligation
15. desire
16. usuality
17. intensity
18. type
19. orientation
20. value
21. modalization
22. modulation

(۲) می‌توانید سلسله‌مراتب آن را مشاهده کنید.



شکل (۲). شبکه نظام افزوده وجه (هالیدی و متیسن، ۱۴۰۲:۲۰)

دومین زیرنظام، «جهت‌گیری» است. این زیرنظام، دو نوع تقابل را نشان می‌دهد: تقابل شخصی^۱ و بی‌طرفانه^۲ و تقابل صريح^۳ و ضمنی^۴. برای درک بهتر، این دو نوع تقابل در جدول (۱) با مثال نشان داده شده است.

جدول (۱). تحلیل نمونه‌ها براساس زیرنظام جهت‌گیری (هالیدی و متیسن، ۱۴۰۲:۲۰)

جهت‌گیری	شخصی	بی‌طرفانه
ضمنی	باید	قطعاً
صريح	مطلوب	مسلم است

در مثال‌های «باید» و «مطلوب» که از نوع شخصی هستند، نویسنده منبع نظر را ذکر می‌کند؛ در حالی که در «قطعاً» و «مسلم است»، منبع آن مشخص نیست و حالت بی‌طرفانه دارد. درباره «باید»، ذکر منبع نظر به صورت ضمنی و در «مطلوب» به صورت صريح بیان شده است (هالیدی و متیسن، ۱۴۰۲:۲۰).

سومین زیرنظام، «مقدار» است که سه سطح «بالا»، «پایین» و «میانه» دارد.

چهارمین زیرنظام وجه‌نمایی، «قطبیت» است. قطبیت تقابل میان مثبت و منفی است. قطبیت را می‌توان به‌نوعی دو سر پیوستار وجهیت در نظر گرفت (میرزاچی، ۱۴۰۰).

در ادامه، مثال‌هایی از افزوده‌های وجه در جملات پیکره پژوهش حاضر ذکر شده است. در جدول (۲)، افزوده‌های وجه در این مثال‌ها بنابر شبکه نظام وجه‌نمایی تحلیل شده‌اند.

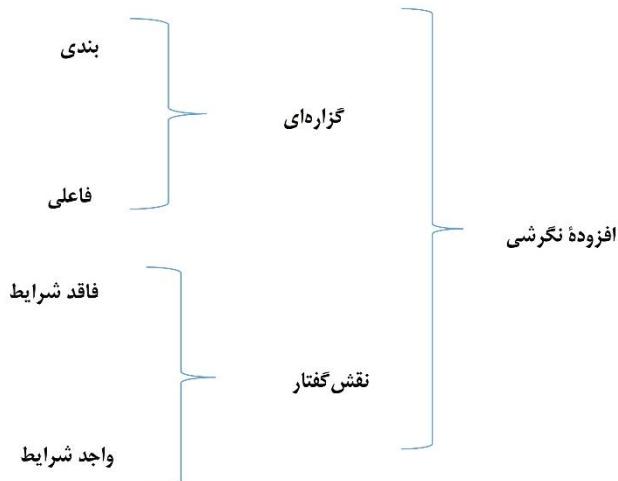
1. subjective
2. objective
3. explicit
4. implicit

۱۰. فولاد گفت: «یعنی ممکنه که تو تب و هذیان از خونه زده باشه بیرون و تو نخلستان، گوشه‌ای افتاده باشه و سرما خشکش کرده باشه؟» (محمد، ۱۳۸۱).
۱۱. با این حرف‌ها نمی‌خواهم ناراحتت کنم؛ اما تو باید بدانی، باید بفهمی، حتماً کریستین برایت نگفته اگرنه کار به اینجاها نمی‌کشید (گلشیری، ۱۳۵۰).
۱۲. عمه بزرگ گفت: «خسرو خان، از یک شازده بعید است که بادبادک پسر باغان را بردارد (گلشیری، ۱۴۰۰).
۱۳. این بهت و درنگ گهگاهی از صبح با شیرو بود (دولت‌آبادی، ۱۴۰۱).
۱۴. من تصمیم دارم هر شب به بیایم پیش تو، بهشرط اینکه بازهم از این چیزها بنویسی (سعادی، ۱۳۷۷).

جدول (۲). تحلیل نمونه‌ها براساس شبکه نظام وجهنمایی

مثال	نوع (سطح اول)	نوع (سطح دوم)	جهت‌گیری	مقدار	قطیعت
ممکنه	وجه‌سازی	احتمالی	بی‌طرفانه	صریح	مثبت میانه
حتماً	وجه‌سازی	احتمالی	بی‌طرفانه	ضمی	مثبت بالا
بعید است	وجه‌سازی	احتمالی	بی‌طرفانه	صریح	منفی پایین
گهگاهی	وجه‌سازی	عادتی	بی‌طرفانه	ضمی	مثبت پایین
نمی‌خواهم	تعديل‌سازی	تمایل	شخصی	صریح	منفی بالا
باید	تعديل‌سازی	التزام	شخصی	ضمی	مثبت بالا
تصمیم دارم	تعديل‌سازی	تمایل	شخصی	صریح	مثبت بالا

شبکه نظام دیگر، شبکه افزوده نگرشی است. این افزوده‌ها نظر نویسنده یا گوینده را بیان می‌کنند و هدف آن‌ها محتوای گزاره یا بخشی از نقش گفتار است؛ از این‌رو، به دو گروه گزاره‌ای^۱ و نقش گفتار^۲ تقسیم می‌شوند. در افزوده نگرشی از نوع گزاره‌ای، گوینده یا نویسنده نظر خود را درباره کل گزاره یا بخشی از آن (فاعل) بیان می‌کند. پس افزوده نگرشی، گزاره‌ای به دو نوع بندی و فاعلی تقسیم می‌شود. افزوده نگرشی از نوع نقش گفتار نیز به دو نوع فاقد شرایط^۳ و واجد شرایط^۴ تقسیم می‌شود (هالیدی و متیسن، ۱۹۰۲؛ ۲۰۱۴). در شکل (۳)، شبکه نظام افزوده نگرشی مشاهده می‌شود.



شکل (۳). شبکه نظام افزوده نگرشی (هالیدی و متیسن، ۲۰۱۴)

در شکل (۴) و (۵)، افزوده بندی و فاعلی و در شکل (۶) افزوده نقش گفتار نمایش داده شده است.
در مثال (۱۵) و (۱۶) می‌توانید به ترتیب نمونه‌ای از «افزوده گزاره‌ای، بندی، صلاحیتی^۵، فرض، شایعه^۶» و «افزوده گزاره‌ای، بندی،

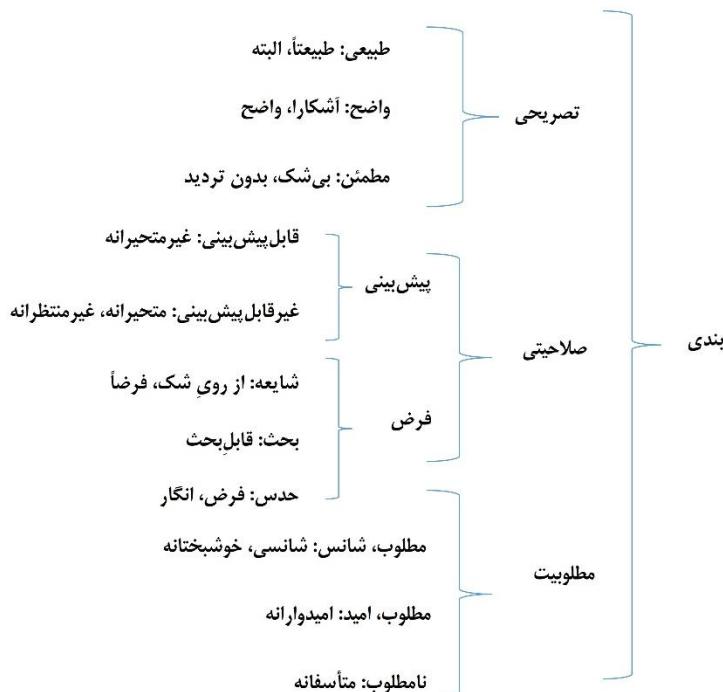
1. propositional
2. speechfunctional
3. unqualified
4. qualified
5. qualificative
6. hearsay

مطلوبیت^۱، غیرمطلوب» را مشاهده کنید.

۱۵. بر فرض هم که خواهرم با این عنکبوت مشغولیتی پیدا کرده باشد، تازه به من چه؟ عنکبوت، عنکبوت است دیگر (آل احمد، ۱۳۵۰).

۱۶. اگر خود شما دختر داشتید، به همچو آدمی شوهرش می‌دادید؟ گفت: «متأسفانه من دختر ندارم» (آل احمد، ۱۳۵۰).

شکل (۴) شبکه نظام افزوده گزاره‌ای بندی هالیدی و متیسن (۲۰۱۴) را نشان می‌دهد. در این شکل می‌توانید سلسه‌مراتب افزوده گزاره‌ای بندی به کاررفته در مثال‌های (۱۵) و (۱۶) را مشاهده کنید.



شکل (۴). شبکه نظام افزوده گزاره‌ای بندی (هالیدی و متیسن، ۲۰۱۴: ۲۰۱۴)

در مثال (۱۷)، نمونه‌ای از «افزوده گزاره‌ای، فاعلی، اخلاقی، منفی» ذکر شده است.

۱۷. یک کتابخانه نفیس تخصصی در باب معماری داشت؛ اما حتی اشتباه، یک دیوان حافظ و مولوی در کنار آن مجموعه نفیس، جای نگرفته بود (ابراهیمی، ۱۳۷۴).

شکل (۵) شبکه نظام افزوده گزاره‌ای فاعلی هالیدی و متیسن (۲۰۱۴) را نشان می‌دهد. در این شکل می‌توانید سلسه‌مراتب افزوده گزاره‌ای فاعلی به کاررفته در مثال (۱۷) را مشاهده کنید.



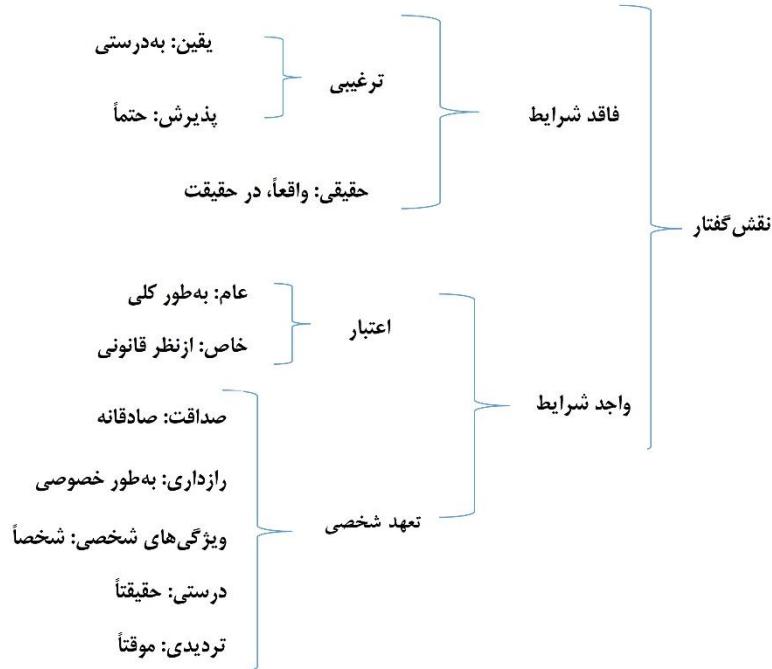
شکل (۵). شبکه نظام افزوده گزاره‌ای فاعلی (هالیدی و متیسن، ۲۰۱۴: ۲۰۱۴)

مثال‌های (۱۸) و (۱۹) به ترتیب نمونه‌هایی از «افزوده نقش‌گفتار، فاقد شرایط، حقیقی» و «افزوده نقش‌گفتار، واجد شرایط، اعتبار^۱، عام» هستند.

۱۸. شاید حقیقتاً هم اسد نمی‌ترسید و حس ترس سامون بود که او را وامی داشت بپندارد برادرش هم می‌ترسد (دولت‌آبادی، ۱۳۹۵).

۱۹. به طور کلی، تو کموکسر نداری؟ (سعیدی، ۱۳۷۷).

شکل (۶) شبکه نظام افزوده نقش‌گفتار هالیدی و متیسن (۲۰۱۴) است.



شکل (۶). شبکه نظام افزوده نقش‌گفتار (جعفری، ۱۴۲: ۱۳۸۸؛ هالیدی و متیسن، ۱۹۱: ۲۰۱۴)

۲-۲ واژه‌های دستوری

بنابر تعریف ردفورد^۲ (۲۰۰۴)، واژه‌های دستوری، اطلاعاتی درباره نقش‌های دستوری متناسب به برخی مفاهیم (مانند شخص، شمار، جنس و حالت) دارند و معنای قائم به ذات ندارند. با این توضیح، حرف تعریف^۳، کمی‌نما^۴، ضمیر، فعل کمکی، علامت مصدر و متمم‌نما^۵ جزء مقوله‌های دستوری به حساب می‌آیند. در این پژوهش، در تعریف واژه‌های دستوری دو ملاک در نظر گرفته شده است. اگر واژه موردنظر مسئول انتقال مفهومی دستوری باشد یا اگر خودش به صورت مستقل معنی نداشته باشد، آنگاه آن واژه، دستوری است. به‌این ترتیب، حروف اضافه که حوزه معنایی‌شان در همنشینی با واژه‌های دیگر مشخص می‌شود، دستوری محسوب می‌شوند (میرزاچی و صفری، ۱۳۹۴: ۲۵۴-۲۵۵). در مجموع، در پژوهش حاضر، حرف اضافه، کمی‌نما، ضمیر، فعل کمکی، همکرد فعل (فعل سبك^۶، متمم‌نمای «که»، حرف تعریف «یه» و نقش‌نمای مفعولی «را») کلمات دستوری به شمار می‌آیند.

۳- پیکره پژوهش

در پژوهش حاضر، به منظور طراحی سامانه‌ای برای تشخیص خودکار هویت نویسنده متون فارسی، پیکره‌ای از آثار هفت نویسنده معاصر ایرانی به نام‌های هوشنگ گلشیری، بزرگ علوی، احمد محمود، محمود دولت‌آبادی، نادر ابراهیمی، جلال آل احمد و غلامحسین سعیدی گردآوری و هنجارسازی^۷ شد. منبع به کاررفته برای گردآوری این داده، پایگاه داده‌های زبان فارسی (عاصی، ۱۹۹۷) و پیکره

1. validity

2. A. Radford

3. article

4. quantifier

5. complementizer

6. light verb

7. normalization

متنی زبان فارسی (بی‌جن‌خان و دیگران، ۲۰۱۱) بوده است. علاوه بر این، آثار مختلف هفت نویسنده در شبکه جهانی وب جستجو شد و کتاب‌های آن‌ها که در قالب پی‌دی‌اف^۱ بودند، با نرم افزار ایبو^۲ به قالب متنی^۳ درآمدند. درنهایت، کل پیکره هنجارسازی و یکدست شد. در جدول (۳)، آمارهای این پیکره نشان داده شده است. شایان ذکر است از آنجاکه در بیشتر این آثار از زبان «محاوره» استفاده شده است و ابزارهای پیش‌پردازشگر^۴ زبان فارسی درباره زبان محاوره کارایی نامطلوبی دارند یا دسترسی به آن‌ها محدود است، پیکره به صورت خام و فاقد برچسب در نظر گرفته شده است. همچنین روش پیشنهادی در این پژوهش مستقل از ابزارهای پیش‌پردازشگر است.

جدول (۳). آمارهای پیکره داستانی

نام نویسنده	تعداد آثار	مجموع کل واژه‌ها
نادر ابراهیمی	۸	۲۶۱۸۶۶
احمد محمود	۹	۳۶۱۵۶۵
جلال آل احمد	۹	۲۵۴۲۷۶
بزرگ علوی	۷	۳۲۶۸۰۲
هونسگ گلشیری	۱۲	۲۴۷۷۹۱
محمد دولت آبادی	۸	۳۴۶۱۳۳
غلامحسین ساعدی	۶	۳۲۲۳۵۸
مجموع	۵۹	۲۱۲۱۷۹۰

۴- روش پژوهش

در پژوهش پیش‌رو، برای تشخیص خودکار هویت نویسنده متن از رویکرد نقش‌گرای نظاممند هالیدی (هالیدی و متیسن، ۲۰۱۴) و روش پیشنهادی در پژوهش آرگامون و دیگران (۲۰۰۷) استفاده شده است. به این منظور، ابتدا فهرستی شامل واژه‌های دستوری، یک مجموعه واژگان برای افزوده‌های ربطی، وجه و نگرشی براساس رویکرد نقش‌گرای نظاممند هالیدی و پیکره‌ای از آثار هفت نویسنده معاصر گردآوری شد (ارجاع به بخش ۳). سپس الگوریتمی^۵ طراحی شد که کلماتی از متن پیکره را که در فهرست واژه‌های دستوری یا مجموعه واژگان تعریف شده‌اند، استخراج و بسامد نسبی شاخص‌های تعریف‌شده برای هر متن را محاسبه می‌کرد. بسامد نسبی شاخص‌ها در این پژوهش شامل بسامد نسبی هریک از واژه‌های دستوری و بسامد نسبی هر گره در شبکه نظام‌های مبتنی بر دستور نقش‌گرای هالیدی (هالیدی و متیسن، ۲۰۱۴) است. در مرحله بعد، مقدار هریک از شاخص‌ها در هر متن بهمنزله معیاری برای تمایزگذاشتن میان متنون مختلف در نظر گرفته شد. به این شکل که الگوریتم یادگیری ماشینی، بُردار ویژگی‌ها^۶ را که شامل هریک از شاخص‌های تعریف‌شده برای متنون است، دریافت می‌کرد و با توجه به تفاوت میان مقادیر این شاخص‌ها بین سبک نویسنده‌گان تمایز قائل می‌شد. در ادامه، همه این مراحل به تفصیل شرح داده می‌شود.

۴- استخراج کلمات از متن

واژگان، کلمات و عباراتی را شامل می‌شود که به صورت نیمه‌خودکار^۷ از پیکره یا شبکه واژگان گردآوری شده است. هر مدخل واژگان شماری از ویژگی‌های معنایی براساس دستور نقش‌گرای نظاممند را دربردارد. برای گردآوری ویژگی‌های معنایی واژگان از سه منبع پیکره گفتمانی زبان فارسی (میزایی و صفری، ۲۰۱۸)، فارس‌نت (شمس‌فرد و دیگران، ۲۰۱۰) و پیکره گردآوری شده در پژوهشی در حوزه دستور نقش‌گرای نظاممند (جعفری، ۱۳۸۸) بهره گرفته شده است. پیکره گفتمان زبان فارسی جزء محدود پیکره‌های جهان است که در سطح گفتمان به صورت دستی برچسب‌گذاری شده است. پیکره گفتمان زبان فارسی در دو سطح درون جمله‌ای (بینابندی) و درون متنی (بیناجمله‌ای) تهیه شده است. کلیات شیوه برچسب‌گذاری این پیکره که در مجموع حجمی بالغ بر یک میلیون کلمه دارد،

1. PDF
2. <https://www.eboo.ir/>
3. text (txt)
4. preprocessor
5. algorithm
6. feature vector

۷. منظور از نیمه‌خودکار این است که در ابتدا فهرست کلمات به صورت خودکار گردآوری می‌شود؛ سپس زبان‌شناس به صورت دستی آن را دسته‌بندی و برچسب‌گذاری می‌کند.

براساس استاندارد درخت‌بانک گفتمانی پن^۱ است (پراساد^۲ و دیگران، ۲۰۰۸). این شیوه‌نامه به لحاظ نظری در بحث روابط منطقی از رویکرد نقش‌گرای هالیدی و متیسن (۲۰۱۴) در فرانش منطقی^۳ پیروی می‌کند. علاوه‌بر این، در پیکره گفتمان برای سه مفهوم وجه، قطبیت و قطبیت برچسب‌گذاری صورت گرفته است (شمس‌فرد و بی‌جن‌خان، ۱۴۰۱: ۷۳). فارس‌نت نیز بزرگ‌ترین شبکه واژگان^۴ زبان فارسی است. جعفری (۱۳۸۸)، افزوده‌ها در زبان فارسی را براساس رویکردهای نقشی و صوری بررسی و در این زمینه پیکره‌ای گردآوری کرده است. در ادامه، نحوه گردآوری واژگان برای انواع افزوده‌ها و فهرست واژه‌های دستوری بیان شده است.

همان‌گونه که پیش‌تر اشاره شد، افزوده‌های ربطی در فرانش منتبی مطرح هستند و بین دو بند یا دو جمله پیوند منطقی برقرار می‌کنند. برای تهیه فهرست افزوده‌های ربطی، کل حروف ربط موجود در پیکره گفتمان استخراج شد. در پیکره گفتمان به پیروی از درخت‌بانک گفتمانی پن برچسب‌های نماینده معنای منطقی در چهار گروه کلی شامل زمانی^۵، وابستگی^۶، مقایسه^۷ و گسترش^۸ دسته‌بندی می‌شوند. در این دسته‌بندی هر گره به دو زیربخش «نوع» و «زیرنوع» تقسیم‌بندی می‌شود (شمس‌فرد و بی‌جن‌خان، ۱۴۰۱: ۸۰). ازانجاكه هریک از حروف ربط می‌تواند در پیکره بیش از یک برچسب داشته باشد، فقط آن حروفی انتخاب شد که در بیش از ۶۰ درصد موارد، یک نوع برچسب معین دارد. به این ترتیب، ۳۷۲ حرف ربط انتخاب شد. پس از استخراج این فهرست، برچسب هریک از حروف ربط به صورت دستی بررسی شد و براساس شبکه نظام ربط نمایش‌داده شده در شکل (۱) بازبینی و دوباره دسته‌بندی شد.

برای تهیه فهرست افزوده‌های وجه و نگرشی از پیکره گفتمان (میرزاپی و صفری، ۲۰۱۸)، فارس‌نت (شمس‌فرد و دیگران، ۲۰۱۰) و پیکره پژوهش جعفری (۱۳۸۸) استفاده شد. برای تهیه فهرست افزوده‌های وجه، فهرست کلمات دارای سه نوع برچسب «وجه»، «قطبیت» و «قطبیت» از پیکره گفتمان استخراج شد و براساس شبکه نظام وجه‌نمایی که در شکل (۲) مشاهده می‌شود، دسته‌بندی شد. علاوه‌بر این، از پیکره پژوهش جعفری (۱۳۸۸) برای تهیه فهرست افزوده‌وجه و نگرشی استفاده شد. برای افزوده‌های نگرشی مستخرج از پیکره جعفری، فهرست کلمات مترادف با آن‌ها با کمک فارس‌نت یافته و به مجموعه واژگان افزوده شد. ازانجاكه در برخی آثار نویسنده‌گان پیکره معاصر از زبان محاوره استفاده شده است، بعضی عبارت‌ها که صورت محاوره‌ای دارند؛ مانند «علومه»، «ممکنه» نیز برچسب‌گذاری و به مجموعه واژگان افزوده شد. همچنین صورت‌های منفی مانند «علوم نیست» در مقابل «علوم است» نیز در مجموعه واژگان گنجانده شد. علاوه‌بر این، صورت‌های تصریفی افعالی مانند «فکر کردن»، «حس کردن»، «خواستن» و «دوست‌داشتن» نیز در مجموعه واژگان قرار گرفت. در مجموع، ۳۲۲ افزوده وجه و ۲۰۱ افزوده نگرشی برچسب‌گذاری شد.

از ازانجاكه فهرست واژه‌های دستوری و محتوایی به حوزه تخصصی یا گونه^۹ هر متن وابسته است (میرزاپی و صفری، ۱۳۹۴)، برای تهیه فهرست واژه‌های دستوری، از پیکره گردآوری شده در پژوهش حاضر استفاده شد. به این منظور، از روش وزن‌دهی فرکانس کلمه-معکوس فرکانس سند^{۱۰} استفاده شد^{۱۱}. براساس معیار فرکانس کلمه-معکوس فرکانس سند، ۱۹۷ واژه‌ای که مقادیر کوچک‌تری داشتند، واژه دستوری در نظر گرفته شدند. تا اینجا نحوه گردآوری واژگان شرح داده شد. در ادامه، نحوه عملکرد سامانه تشریح می‌شود.

در ابتدا، کلماتی از متن که در مجموعه واژگان تعریف شده‌اند، استخراج می‌شوند؛ سپس براساس برچسب آن واژه یا عبارت در مجموعه واژگان، برچسب‌گذاری می‌شوند. برای نمونه، حرف ربط «برای مثال»، در مجموعه واژگان براساس نظام حروف ربط به ترتیب سلسه‌مراتب دارای برچسب «تشریحی»، «بدلی»، «نمونه‌سازی» است. سامانه، تمام موارد وقوع عبارت «برای مثال» را در متن کشف و براساس برچسب واژگان برچسب‌گذاری می‌کند. برای استخراج کلمات از متن سعی بر آن بود که اگر یک کلمه یا عبارت زیرمجموعه عبارت دیگری در مجموعه واژگان باشد (مانند «که» و «به‌محض آنکه»)، برچسب عبارت بزرگ‌تر در نظر گرفته شود.

1. Penn discourse treebank

2. R. Prasad

3. logical metafunction

4. WordNet

5. temporal

6. contingency

7. comparison

8. expansion

9. genre

10. tf-idf

۱۱. در این روش میزان تکرار یک کلمه در یک مستند در مقابل تعداد تکرار آن در مجموعه کلیه مستندات سنجیده می‌شود. در این روش به هر کلمه در یک متن عددی تخصیص می‌دهد. این معیار برای کلماتی که تقریباً در تمام استاد پیکره یافت شوند، دارای مقادیر کمینه است. این کلمات همان واژه‌های دستوری تلقی می‌شوند (شوتز و دیگران، ۲۰۰۸).

۴-۲ محاسبه بسامد نسبی شاخص‌ها

پس از استخراج کلمات از متن، بسامد نسبی مقادیر شاخص‌های معنایی برای هر متن محاسبه می‌شود. خروجی این مرحله بردار ویژگی‌های معنایی است که توصیفگر متن است. براساس ویژگی‌های مبتنی بر دستور نقش‌گرای هالیدی (هالیدی و متیسن، ۲۰۱۴) و واژه‌های دستوری هر متن با بردار ویژگی‌های عددی تعریف می‌شود.

بسامد نسبی هر گره در نظام‌های مبتنی بر دستور نقش‌گرای هالیدی¹، بسامد انتخاب گره O1 بر حسب انتخاب O2 است که گره والد آن در شبکه نظام محسوب می‌شود. در حقیقت، گره O2 دارای برچسب درشت² و O1 دارای برچسب ریز³ است و زیرمجموعه آن برچسب تلقی می‌شود. بسامد نسبی O1 با داشتن گره O2 بهمنزله گره والد به این شکل تعریف می‌شود:

$$RF_d(O_1 | O_2) = \frac{N_d(O_1, O_2)}{N_d(O_2)} \quad (\text{فرمول ۱})$$

(آرگامون و دیگران، ۲۰۰۷)

در این فرمول، $N_d(O_1, O_2)$ تعداد رخداد همزمان O1 و O2 است و $N_d(O_2)$ تعداد رخداد O2 در هر متن است و d به معنای متن یا همان سند است (آرگامون و دیگران، ۲۰۰۷: ۸). بهیان ساده‌تر، چه نسبت از تعداد رخداد کلمات در متن که دارای برچسب O2 هستند، دارای برچسب ریزتر O1 نیز هستند.

برای نمونه، در شبکه نظام حروف ربط، گره‌های «تشریحی»، «گسترشی» و «تفصیلی» زیرمجموعه گره حرف ربط محسوب می‌شوند. بسامد نسبی گره «تشریحی» با داشتن گره «حرف ربط» به این معناست که چه نسبت از حروف ربط به کار گرفته شده در یک متن، از نوع تشریحی هستند. درباره شبکه نظام وجه‌نمایی و افزوده نگرشی نیز بسامد نسبی براساس فرمول (۱) محاسبه می‌شود. برای مثال، در شبکه نظام وجه‌نمایی، گره‌های «بالا»، «پایین» و «میانه» زیرمجموعه گره «مقدار» هستند. بسامد نسبی گره «بالا» با داشتن گره «مقدار» به این معناست که چه نسبت از افزوده‌های وجه در یک متن، دارای مقدار «بالا» هستند.

علاوه بر ویژگی بسامد نسبی، صرفاً برای نظام وجه‌نمایی، ویژگی‌هایی براساس ترکیب گره‌ها تعریف می‌شود. برای هر جفت گره در زیرنظام‌های مختلف وجه‌نمایی (مانند «نوع» و «مقدار»)، بسامد نسبی واژه‌هایی که با نوع دو گره برچسب خورده‌اند، براساس ترکیب گره‌های والد آن‌ها تعریف می‌شود (آرگامون و دیگران، ۲۰۰۷). برای مثال، بسامد نسبی جفت گره «وجه احتمال-عادت» و «بالا» با داشتن جفت گره «نوع» و «مقدار» بیان می‌کند که چه نسبت از کلماتی که دارای «وجه احتمال-عادت» هستند، در زیرنظام «مقدار» دارای مقدار «بالا» نیز هستند؛ (مانند «حتماً» و «دائماً»).

برای مقایسه کارایی ویژگی‌های مبتنی بر دستور نقش‌گرای هالیدی و ویژگی واژه‌های دستوری، ویژگی بسامد واژه‌های دستوری تعریف می‌شود. به این منظور، واژه‌های دستوری در هر متن شناخته می‌شوند و بسامد نسبی هریک از آن‌ها بهمنزله یک ویژگی محاسبه می‌گردد. برای محاسبه بسامد نسبی واژه‌های دستوری از فرمول (۲) استفاده شده است:

$$\frac{\text{count}(w)}{\sum_{w' \in FW} \text{count}(w')} \quad (\text{فرمول ۲})$$

(آرگامون و دیگران، ۲۰۰۷)

در این فرمول، W هریک از واژه‌های دستوری است که بسامد آن نسبت به بسامد کل واژه‌های دستوری در یک متن خاص محاسبه می‌شود (آرگامون و دیگران، ۲۰۰۷: ۱۳). در صورتِ کسر فرمول (۲)، تعداد رخداد یک واژه دستوری خاص و در مخرج آن تعداد رخداد کل واژه‌های دستوری در متن قرار دارد.

۴-۳ یادگیری ماشینی

برای مرحله یادگیری ماشینی از روش یادگیری با ناظر⁴ استفاده می‌شود. در این روش به یک سامانه، مجموعه‌ای از جفت‌های ورودی-خروجی ارائه می‌شود و سامانه می‌کوشد تابعی از ورودی به خروجی را فراگیرد. یادگیری باناظر به تعدادی داده ورودی برای

۱. هر شبکه نظام در هر سطح شامل چند گره است. برای مثال، شبکه نظام حروف ربط در سطح اول شامل سه گره، افزوده تشریحی، گسترشی و تفصیلی است. در سطح بعد، گره تشریحی شامل دو گره بدلي و واضح‌سازی است. در حقیقت، گره تشریحی والد دو گره بدلي و واضح‌سازی است. در اینجا گره تشریحی نسبت به دو گره بدلي و واضح‌سازی دارای برچسب درشت و دو گره بدلي و واضح‌سازی دارای برچسب ریزتر هستند.

2. coarse-grained

3. fine-grained

4. supervised learning

آموزش سامانه نیاز دارد. همان‌طور که پیش‌تر اشاره شد، خروجی مرحله دوم بردار ویژگی‌های معنایی است که توصیفگر متن است. درمورد تشخیص خودکار نویسنده متن، ورودی‌ها بردار ویژگی‌های زبانی متون هستند و خروجی همان نام نویسنده متن است.

در پژوهش حاضر، برای دسته‌بندی نویسنده‌گان، از روش یادگیری عمیق^۱ استفاده شده است. رویکردهای مبتنی بر یادگیری عمیق در پژوهش‌های نوین در حوزه پردازش زبان طبیعی از جمله تشخیص خودکار هویت نویسنده بسیار موردنوجه هستند (اوچندو^۲ و دیگران، ۲۰۲۰). یکی از انواع طبقه‌بندی‌های روش یادگیری عمیق، طبقه‌بند پرسپترون چند لایه^۳ است که از آن در این پژوهش بهره گرفته شده است. برای استفاده از این طبقه‌بند از یک ابزار^۴ یادگیری ماشین به زبان پایتون^۵ استفاده شده است. الگوریتم یادگیری، بردار ویژگی‌های معنایی هر متن را به منزله ورودی دریافت می‌کند. بردار ویژگی‌های معنایی می‌تواند انواع ویژگی‌های مبتنی بر دستور نقش‌گرای هالیدی (شبکه نظام حروف ربط، وجهنمایی و افزوده نگرشی) یا ترکیب انواع مختلف آن‌ها را دربرگیرد. ازسوی دیگر، این بردار می‌تواند ویژگی بسامد نسبی واژه‌های دستوری را شامل شود. در حالت دیگر، در انتخاب نوع بردار ویژگی می‌توان تمام ویژگی‌های مبتنی بر دستور نقش‌گرای هالیدی و ویژگی بسامد نسبی واژه‌های دستوری را باهم آمیخت. درنهایت، الگوریتم یادگیری نام نویسنده متن را به منزله خروجی برمی‌گرداند. در ادامه، کارایی این الگوریتم در حالت‌های مختلف بردار ویژگی ارزیابی و گزارش می‌شود.

۵- یافته‌ها

برای ارزیابی کیفیت سامانه طراحی شده در تشخیص خودکار هویت نویسنده متن از روش ارزیابی مقاطع K تایی^۶ استفاده شده است. اگر کل داده‌ها را به طور تصادفی به K زیرنمونه تقسیم کنیم، می‌توانیم در هر مرحله از فرایند، تعداد K-1 از این لایه‌ها را به منزله مجموعه‌داده آموزشی و یکی را به منزله مجموعه‌داده آزمون در نظر بگیریم. مشخص است که تعداد تکرارهای فرایند برابر با K خواهد بود (رفائلزاده و دیگران، ۲۰۰۹). درواقع، یادگیری سامانه با کمک داده آموزشی صورت می‌گیرد و با استفاده از داده آزمون ارزیابی می‌شود. در این پژوهش، $K=5$ در نظر گرفته شده است. نکته درخور توجه در ارزیابی این است که نه تنها داده آموزش و آزمون با یکدیگر همپوشانی ندارند، بلکه برای ارزیابی سامانه تشخیص سبک نگارش یک نویسنده، نباید یک داستان خاص بین داده آموزش و آزمون تقسیم شود. این نکته‌ای است که در برخی پژوهش‌ها نادیده گرفته شده است؛ به‌این‌علت، در ارزیابی سامانه، کل آثار هر نویسنده به پنج قسمت تقسیم شد؛ چهار قسمت برای آموزش و یک قسمت برای آزمون. این تقسیم‌بندی به‌گونه‌ای است که داستان‌های موجود در بخش آموزش از داستان‌های موجود قسمت آزمون متمایز هستند. برای محاسبه کارایی سامانه از معیار دقت^۷ استفاده شد. دقت در تشخیص خودکار نویسنده عبارت است از نسبت نتایج درست به دست آمده از سامانه به کل تعداد نمونه‌های موجود در داده آزمون (درونه و شریعتی، ۲۰۱۴). از آنجاکه فرایند ارزیابی پنج بار تکرار شد، درنهایت، از نتایج بدست آمده در پنج مرحله برای کل سامانه و همین‌طور برای هر نویسنده میانگین وزن‌دار^۸ گرفته شد.^۹

الگوی طراحی شده در چند حالت آزموده شد: حالت نخست، بردار ویژگی‌های شامل ویژگی‌های تعريف‌شده براساس دستور نقش‌گرای نظاممند است. حالت دوم، بردار ویژگی از نوع ویژگی‌های واژه‌های دستوری است. حالت سوم، ترکیب حالت نخست و دوم است. در هر حالت، دقت سامانه به روش ارزیابی مقاطع K تایی سنجیده شد. در جدول (۴) نتایج ارزیابی سامانه به‌طور خلاصه گزارش شده است. همان‌گونه که مشاهده می‌شود، بهترین نتایج حاصل از ترکیب روش مبتنی بر دستور نقش‌گرای نظاممند و بسامد واژه‌های دستوری است. همچنین دقت روش مبتنی بر واژه‌های دستوری از روش دستور نقش‌گرای بسیار بیشتر است. در شکل (۷)، نتایج ارزیابی سامانه به‌طور کامل و برای هر نویسنده به‌طور مجزا نمایش داده شده است. علاوه‌براین، میزان کارایی تمام ویژگی‌های تعريف‌شده در سامانه

1. deep learning

2. A. Uchendu

3. multilayer perceptron

4. <https://scikit-learn.org/>

5. python

6. K-Fold Cross Validation

7. accuracy

8. weighted mean

9. در محاسبه میانگین وزن‌دار یک مجموعه عامل نابرایر، برای هریک از عامل‌ها، وزن یا ارزش معینی در نظر گرفته می‌شود؛ سپس آن عامل در وزن معین ضرب می‌گردد. آنگاه جمع این ارقام به دست آمده بر مجموع وزن‌ها تقسیم می‌شود.

بررسی و کارترین ویژگی‌ها در عملکرد سامانه انتخاب شد. برای این کار از آزمون F تحلیل واریانس یک‌طرفه^۱ استفاده شد.^۲ در این پژوهش مقادیر بدار ویژگی (کل ویژگی‌های مبتنی بر دستور نقش‌گرای نظاممند و ویژگی واژه‌های دستوری)، براساس نتایج به دست آمده از آزمون F تحلیل واریانس یک‌طرفه مرتب و ۱۵۰ ویژگی برتر انتخاب شد. براساس این معیار، بسامد نسبی واژه‌های دستوری «آن»، «رو» و «شد» بهترین دارای بالاترین امتیاز در میان کل ویژگی‌ها هستند.

جدول (۴). نتایج ارزیابی کلی سامانه براساس معیار دقت

نام مجموعه ویژگی	كلمات دستوری	كلمات دستوری و نقش‌گرا	كلمات دستوری و وجه و نگرشی	كلمات دستوری و نگرشی	كلمات دستوری و افزوده وجه و نگرشی	كلمات دستوری و افزوده	كلمات دستوری و افزوده + نقشگری	كلمات دستوری و نقشگری
میانگین وزن دار	۶۸.۹۸	۷۲.۵۳	۷۲.۰۵	۴۶	۷۹.۳۱	۷۴	۷۹.۳۱	۷۹.۳۱



شکل (۷). نمودار مقایسه‌ای ارزیابی سامانه براساس معیار دقت

پس از انتخاب بهترین ویژگی‌ها کارایی سامانه در دو حالت سنجیده شد: (الف) کلمات دستوری؛ (ب) کلمات دستوری (بهترین ویژگی‌ها) و ویژگی‌های مبتنی بر دستور نقش‌گرا. این نتایج در جدول (۵) گزارش شده است. همان‌گونه که در شکل (۸) مشاهده می‌شود، بهترین نتایج را ترکیب حالت بهترین کلمات دستوری و دستور نقش‌گرا به دست می‌دهد.

جدول (۵). نتایج ارزیابی سامانه براساس معیار دقت (بهترین ویژگی‌ها)

میانگین وزن دار	نام مجموعه ویژگی
۷۰/۴۷	بهترین کلمات دستوری
۷۴/۴۷	بهترین کلمات دستوری و دستور نقش‌گرا



شکل (۸). نمودار مقایسه‌ای ارزیابی سامانه براساس معیار دقت (بهترین ویژگی‌ها)

1. ANOVA

۲. آزمون تحلیل واریانس یک‌طرفه برای آزمون مقایسه میانگین یک متغیر کمی در میان بیش از دو گروه مستقل استفاده می‌شود.

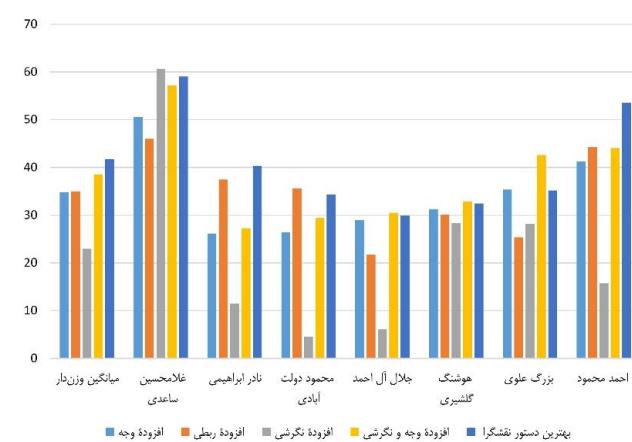
۶- بحث و نتیجه‌گیری

در پژوهش حاضر، برای تعیین هویت نویسنده متن یک سامانه خودکار به روش یادگیری عمیق معرفی شد. برای طراحی سامانه از ویژگی بسامد واژه‌های دستوری و مفاهیم دستور نقش‌گرای نظاممند استفاده شد. سپس عملکرد سامانه در سه حالت ویژگی‌های مبتنی بر واژه‌های دستوری، ویژگی‌های مبتنی بر دستور نقش‌گرای نظاممند و ترکیب این دو نوع ویژگی سنجیده و تحلیل شد و بهترین ویژگی‌ها انتخاب شدند. نتایج ارزیابی سامانه نشان می‌دهد روش محسوبه بسامد واژه‌های دستوری نسبت به روش مبتنی بر دستور نقش‌گرای نظاممند (شبکه نظام ربط، وجهنمایی و افزوده نگرشی) در تشخیص هویت نویسنده متن برتری دارد؛ اما در صورتی که ویژگی‌های زبانی مبتنی بر دستور نقش‌گرای نظاممند هالیدی در کنار ویژگی بسامد واژه‌های دستوری به کار روند، کارایی سامانه نسبت به حالتی که فقط از ویژگی بسامد واژه‌های دستوری استفاده شود، افزایش می‌یابد.

به نظر می‌رسد برای این نتیجه که ویژگی بسامد نسبی واژه‌های دستوری کارایی بالاتری نسبت به ویژگی‌های مبتنی بر دستور نقش‌گرا در تفکیک سبک نویسنده‌گان داشته، دلایل متفاوتی وجود داشته است. دلیل نخست می‌تواند به کنترل ناپذیری خودآگاه نویسنده در استفاده از واژه‌های دستوری مربوط باشد. نویسنده متن واژه‌های دستوری را به طور ناخودآگاه به کار می‌گیرد و برخلاف واژه‌های محتوایی کنترل خودآگاه بر به کاربردن یا به کاربردن آن‌ها ندارد (گلشایی، ۱۳۹۸). از آنجاکه تعیین مرز دقیق بین واژه‌های محتوایی و دستوری عملأً امکان‌پذیر نیست، می‌توان درخصوص واژه‌های دستوری یک پیوستار تعریف کرد. در این پیوستار هرچه به سمت دستوری بودن واژه پیش رویم، کنترل خودآگاه در استفاده از واژه‌ها کاهش می‌یابد. در این پژوهش، براساس آزمون F تحلیل واریانس یک طرفه، ضمایر «آن»، «این»، «آن‌ها»، «من» و «خود» ویژگی‌های بسیار مناسبی برای تمایزگذاشتن میان سبک نویسنده‌گان تلقی می‌شوند. نتایج حاصل از پژوهش حاضر درمورد کاربرین ویژگی‌ها در تشخیص هویت نویسنده گواهی بر این مدعای است که ضمایر در این پیوستار به سمت دستوری بودن تمایل دارند و نویسنده کنترل خودآگاه بر به کارگیری آن‌ها ندارد. بدیهی است که این پیوستار خود می‌تواند موضوع یک پژوهش جدید باشد.

دومین دلیل برای اینکه در تشخیص هویت نویسنده ویژگی‌های مبتنی بر دستور نقش‌گرا به طور مستقل مؤثرتر از واژه‌های دستوری عمل نکرده‌اند، می‌تواند این باشد که استفاده از واژه‌های دستوری به جای یکدیگر، تفاوت سبکی بیشتری ایجاد می‌کند. برای مثال، تفاوت سبک در متونی که از واژه‌های «من» و «اینجانب» استفاده می‌کنند، در خود توجه است؛ این در حالی است که برای مثال، «مسلمان» و «مسلم» است که در زیرنظام جهت‌گیری از شبکه نظام وجهنمایی اولی «ضمی» و دومی «صریح» تلقی می‌شوند، تفاوت سبکی چنانی ایجاد نمی‌کنند. این مطلب درباره «باید» و «تباید» که در زیرنظام قطبیت با یکدیگر تفاوت دارند، نیز صادق است.

دلیل دیگر برای کارایی بیشتر واژه‌های دستوری نسبت به ویژگی‌های مبتنی بر دستور نقش‌گرا، می‌تواند اختلاف در صد حضور واژه‌های دستوری و کلمات مرتبط با سه نوع ویژگی دستور نقش‌گرا در پیکره باشد. به جز افزوده ربطی «و» از شبکه نظام حروف ربط که فراوانی بسیار بالایی در پیکره دارد، در صد حضور واژه‌های دستوری بیشتر از واژه‌های مرتبط با ویژگی‌های مبتنی بر دستور نقش‌گرا است. برای بررسی بهتر ویژگی‌های مبتنی بر دستور نقش‌گرای هالیدی، هریک از این سه شبکه نظام حروف ربط، وجهنمایی و افزوده نگرشی به صورت مجزا و در ترکیب با یکدیگر ارزیابی شدند و نتایج آن‌ها با یکدیگر و با حالت بهترین ویژگی‌های سه نوع نظام مقایسه شدند که در شکل (۹) مشاهده می‌شود.



شکل (۹). نمودار مقایسه‌ای کارایی سامانه با انواع ویژگی‌های دستور نقش‌گرا

همان‌گونه که در نمودار (۹) مشاهده می‌شود، ترکیب بهترین ویژگی‌های مرتب با هر سه نوع افزوده وجه، نگرشی و ربطی بالاترین دقت را در میان دیگر حالتها دارد. پس از آن، افزوده وجهی (افزوده وجه و افزوده نگرشی) قرار دارد. گواه دیگر در برتری افزوده وجهی نسبت به افزوده ربطی، درصد حضور ویژگی‌های مرتب با افزوده وجهی در میان ویژگی‌های منتخب است (۷۰/۳۹ درصد). این در حالی است که درصد حضور ویژگی‌های مرتب با افزوده ربطی در این فهرست ۲۵/۱۱ درصد است.

تحلیل دقیق‌تر بهترین ویژگی‌های افزوده وجهی نشان می‌دهد که ویژگی‌های مرتب با زیرنظام‌های «مقدار» و «نوع» از شبکه نظام افزوده وجهی به دو صورت مستقل و ترکیب با سایر زیرنظام‌ها بسیار کارا هستند. زیرنظام‌های «قطبیت» و «جهت‌گیری» در ترکیب با سایر زیرنظام‌ها به بهبود عملکرد سامانه کمک شایانی می‌کنند. درباره زیرنظام وجه‌سازی (وجه احتمال-عادت) علاوه‌بر اینکه کل زیرنظام و زیرنظام «وجه احتمالی» در کارایی سامانه بسیار مؤثر هستند، زیرنظام «وجه عادتی» بیشترین تأثیر را دارد. در زیرنظام تعديل‌سازی (وجه تمایل-التزام) نیز علاوه‌بر اثرگذاری کل زیرنظام و زیرنظام «وجه التزامی»، زیرنظام «وجه تمایلی» بالاترین کارایی را دارد. در شبکه نظام افزوده نگرشی، زیرنظام گزاره‌ای بهویژه از نوع «خلاصی» و «فرض» بیشترین میزان اثربخشی را دارد.

در نظام شبکه حروف ربط، بسامد افزوده‌های ربطی هریک از سه زیرنظام «تشریحی»، «گسترشی» و «تفصیلی» (به طور مجزا) به کل افزوده‌های ربطی ویژگی‌هایی ارزشمند به شمار می‌روند. برپایه ویژگی‌های منتخب، زیرنظام «گسترشی» نتایجی مطلوب را به دست می‌دهد. در این زیرنظام، بسامد نسبی افزوده‌هایی از نوع «افزایشی» و «تباینی» امتیاز بالای دارند. در زیرنظام «تفصیلی»، زیرنظام «سببی-شرطی» بسیار مؤثر است. در این زیرنظام، زیرنظام «مشخص» بهویژه حروف ربط از نوع «علت» و پس از آن، «نتیجه» تأثیرگذار هستند. در زیرنظام «تشریحی»، افزوده‌های ربطی «بدلی» بهویژه از نوع «نمونه‌سازی» کارآمد هستند.

نتایج کلی این پژوهش همسو با نتایج مقاله مرجع آرگامون و دیگران (۲۰۰۷) است. در پژوهش آرگامان و دیگران (۲۰۰۷)، روش بسامد نسبی واژه‌های دستوری نسبت به روش دستور نقش‌گرا (شبکه نظام حروف ربط، شبکه نظام وجه‌نمایی و شبکه نظام افزوده نگرشی) برتری دارد و ترکیب روش واژه‌های دستوری و دستور نقش‌گرا بالاترین کارایی را دارد. در پژوهش آرگامان و دیگران (۲۰۰۷) روش دستور نقش‌گرا به افزایش کارایی سامانه کمک کرده است که با نتایج کلی پژوهش حاضر همسو است.

یکی از تفاوت‌های پژوهش حاضر با پژوهش آرگامان و دیگران (۲۰۰۷) این است که در پژوهش آرگامان و دیگران (۲۰۰۷)، تعداد واژه‌های دستوری ۶۷۵ واژه در نظر گرفته شده است؛ در حالی که در پژوهش حاضر تعداد کل واژه‌های دستوری ۱۹۷ واژه است و پس از مرحله یافتن بهترین ویژگی‌ها تعداد ۷۴ واژه از واژه‌های دستوری انتخاب شده است. آرگامان و دیگران (۲۰۰۷) با استفاده از الگوریتم طبقه‌بندی ماشین بردار پشتیبانی^۱ و با ۶۷۵ واژه دستوری، تنها با ویژگی بسامد نسبی واژه‌های دستوری به دقتی حدود ۸۵ درصد در تشخیص هویت نویسنده برای زبان انگلیسی دست یافته‌اند. در این پژوهش، برای مقایسه نتایج کار با مقاله مرجع از ۶۴۶ واژه دستوری و الگوریتم ماشین بردار پشتیبان استفاده شد و دقتی معادل ۸۲.۷۵ درصد برای زبان فارسی به دست آمد که به نتایج پژوهش مرجع نزدیک است. در این مقایسه مشخص شد فرایند یادگیری دچار بیش‌برازش^۲ شده است^۳ و این مورد را می‌توان از نقاط ضعف پژوهش مرجع یاد کرد که البته در آن مقاله نیز چند بار به آن اشاره شده است. بهاین‌دلیل، در پژوهش حاضر برای جلوگیری از بیش‌برازش تعداد واژه‌های دستوری بسیار کمتر از مقاله مرجع و برابر با ۱۹۷ کلمه در نظر گرفته شده است. جدا از اینکه تعداد واژه‌های دستوری چقدر است، نتایج حاصل از افزودن ویژگی‌های مبتنی بر دستور نقش‌گرا به سامانه همسو با پژوهش آرگامان و دیگران (۲۰۰۷) است. در مقاله مرجع کارایی سامانه با افزودن ویژگی‌های مبتنی بر دستور نقش‌گرا، حدود ۵ درصد بیشتر از حالتی است که صرفاً از واژه‌های دستوری استفاده شود. این افزایش کارایی برابر با افزایش کارایی پژوهش حاضر در حالت قرارگرفتن ویژگی‌های مبتنی بر دستور نقش‌گرا در کنار واژه‌های دستوری است (ارجاع به جدول ۴). تفاوت دیگر نتایج مقاله مرجع با پژوهش حاضر این است که ویژگی‌های مبتنی بر دستور نقش‌گرای هالیدی (به طور مستقل از واژه‌های دستوری) برای زبان فارسی به اندازه زبان انگلیسی در تشخیص هویت نویسنده کارایی نداشته‌اند. علاوه‌بر تفاوت‌های دو زبان فارسی و انگلیسی، به نظر می‌رسد تفاوت در حجم واژگان تعریف شده برای شبکه نظام‌های دستور نقش‌گرا از عوامل این تفاوت باشد.

1. SVM
2. overfitting

^۳. بیش‌برازش به این معناست که الگوریتم داده‌های آموزشی را بسیار خوب یاد گرفته است؛ ولی توانایی پیش‌بینی خوب داده‌های جدید را ندارد.

شبکه نظام‌های مختلف دستور نقش‌گرا (شبکه نظام حروف ربط، شبکه نظام وجهنمایی و شبکه نظام افزوده نگرشی) به طور مستقل نتایج در خور توجهی را در تعیین هویت نویسنده به دست نمی‌دهند. درواقع، نتایج مطلوب، نتایجی است که از ترکیب ویژگی‌های منتخب از هر سه نظام و ویژگی واژه‌های دستوری به دست می‌آید. گرچه رویکرد نقش‌گرای نظام‌مند هالیدی به‌ویژه در فرانش بینافردی درباره وجه، دسته‌بندی دقیقی ارائه می‌کند، شبکه نظام‌های این دستور به صورت مستقل از واژه‌های دستوری عملکرد مطلوبی در تشخیص هویت نویسنده متن ندارند و فقط در کنار واژه‌های دستوری به افزایش کارایی سامانه یاری می‌رسانند.

از کاستی پژوهش حاضر، می‌توان به این مسئله اشاره کرد که به جز شمار محدودی از افعال در فهرست افزوده وجهی و افعال کمکی، به مقوله فعل در طراحی سامانه هویت نویسنده توجه نشد. در پژوهش‌های آینده می‌توان حجم واژگان برای افزوده‌های ربطی و افزوده‌های وجهی به‌ویژه با مقوله فعل را گسترش داد و به این شکل به پژوهش‌های حوزه دستور نقش‌گرای نظام‌مند هالیدی (هالیدی و متیسن، ۲۰۱۴) کمک کرد. در پژوهش‌های آینده می‌توان الگوریتم استخراج سه نوع ویژگی دستور نقش‌گرا و واژه‌های دستوری را درباره دیگر آثار داستانی نیز به کار برد و بسامد انواع ویژگی‌ها را به دست آورد و از آن در نقد ادبی و سبک‌شناسی برای اهداف زبانی استفاده کرد.

منابع

- آل‌احمد، جلال (۱۳۴۶). *نفرین زمین*. تهران: فردوس.
- آل‌احمد، جلال (۱۳۵۰). *پنج داستان*. تهران: فردوس.
- ابراهیمی، نادر (۱۳۷۴). *یک عاشقانه آرام*. تهران: روزبهان.
- ابراهیمی، نادر (۱۳۹۹). *بر جاده‌های آبی سرخ*. تهران: روزبهان.
- جعفری، آزیتا (۱۳۸۸). بررسی افزوده‌ها در زبان فارسی: براساس رویکردهای نقشی و صوری. *دستور (ویژه‌نامه فرهنگستان)*، ۵(۱)، ۱۲۸-۱۵۵.
- حسین‌حمد، همزه؛ علی‌اکبری، نسرین؛ کریمی، یادگار (۱۴۰۰). بررسی وجه و وجهیت در کردی سورانی: تحلیلی نقش‌گرا. *مطالعات زبان‌ها و گویش‌های غرب ایران*، ۹(۴)، ۱-۲۳.
- دولت‌آبادی، محمود (۱۳۹۵). *روزگار سپری شله مردم سالخورده*. تهران: چشممه.
- دولت‌آبادی، محمود (۱۴۰۱). *کلیلر*. چاپ ۲۷. تهران: فرهنگ معاصر.
- سعادی، غلامحسین (۱۳۷۷). *آشته حلال بیدارخت*. تهران: نگاه.
- سعادی، غلامحسین (۱۳۹۷). *غريبه در شهر*. تهران: نگاه.
- شمس‌فرد، مهرنوش؛ بی‌جن‌خان، محمود (۱۴۰۱). پردازش متن و گفتار فارسی: مروری بر مبانی نظری و آخرین یافته‌های پژوهشی. *تهران: سمت*.
- عارفی، سمیه؛ بصیری، محمدادیسان؛ روزمند، امید (۱۴۰۰). انتخاب ویژگی برای شناسایی نویسنده در متون کوتاه برخط فارسی. *فناوری اطلاعات و ارتباطات ایران*، ۱۳(۴۷-۴۸)، ۳۵-۵۷.
- علوی، بزرگ (۱۳۸۶). *ورق پاره‌های زندان*. تهران: نگاه.
- علوی، بزرگ (۱۳۹۹). *گیله‌مرد*. تهران: نگاه.
- فرهمندپور، زینب؛ نیکمهر، هومن؛ منصوری‌زاده، محروم؛ طبیب‌زاده، امید. (۱۳۹۱). یک سیستم نوین هوشمند تشخیص هویت نویسنده فارسی زبان براساس سبک نوشتاری. *محاسبات نرم*، ۱(۲)، ۲۶-۳۵.
- گلشائی، رامین (۱۳۹۸). واژه‌های دستوری به مثابه نشانگرهای گویش فردی: رویکردی پیکره‌ای به شناسایی هویت نویسنده در زبان فارسی.
- جستارهای زبانی، ۱۰(۳)، ۲۹۳-۳۱۷.
- گلشیری، هوشنگ (۱۳۵۰). *کریستین و کید*. تهران: کتاب زمان.
- گلشیری، هوشنگ (۱۳۷۰). *در ولا پت هوا*. استکهلم: عصر جدید.
- گلشیری، هوشنگ (۱۴۰۰). *شازده/احتجاب*. چاپ ۱۸. تهران: نیلوفر.
- محمود، احمد (۱۳۵۳). *همسایه‌ها*. تهران: امیرکبیر.
- محمود، احمد (۱۳۸۱). *غريبه‌ها و پسرک بومي*. تهران: معین.
- میرزایی، آزاده (۱۳۹۷). *بازتعريف مفاهيم بند پایه و بند پیرو* براساس رویکرد نقش‌گرا. *زبان و زبان‌شناسی*، ۱۳(۲۶)، ۱۱۷-۱۳۲.
- میرزایی، آزاده (۱۴۰۰). *رابطه قطبیت و وجهیت بندی در زبان فارسی*. *مطالعات زبان‌ها و گویش‌های غرب ایران*، ۹(۱)، ۱۱۳-۱۳۵.

میرزایی، آزاده؛ صفری، پگاه (۱۳۹۴). ساختِ واژه-متن‌های تخصصی و عمومی زبان فارسی براساس بسامدگیری واژه‌های نقشی و محتوایی. *مجموعه مقالات نخستین همایش ملی زبان‌شناسی پیکره‌ای* (صص. ۱۷۵-۱۹۱). تهران: نویسه‌پارسی.

References

- Alavi, B. (2007). *Scrap papers from prison*. Tehran: Negah. (In Persian)
- Alavi, B. (2020). *Gilemand*. Tehran: Negah. (In Persian)
- Al-e-Ahmad, J. (1967). *The cursing of the land*. Tehran: Ferdous. (In Persian)
- Al-e-Ahmad, J. (1971). *Five stories*. Tehran: Ferdous. (In Persian)
- Arefi, S., Basiri, M. E., & Roozmand, O. (2021). Feature selection for author identification of Persian online short texts. *Journal of Information and Communication Technology*, 13(47-48), 35-57. <https://dorl.net/dor/20.1001.1.27170414.1400.13.47.4.0> (In Persian)
- Argamon, S., & Koppel, M. (2013). A systemic functional approach to automated authorship analysis. *Journal of Law & Policy*, 21(2), 299-315.
- Argamon, S., Whitelaw, C., Chase, P., Hota, S. R., Garg, N., & Levitan, S. (2007). Stylistic text classification using functional lexical features. *Journal of the American Society for Information Science and Technology*, 58(6), 802-822. <https://doi.org/10.1002/asi.20553>.
- Assi, S. M. (1997). Farsi linguistic database (FLDB). *International journal of Lexicography*, 10(3), 5.
- Bijankhan, M., Sheykhdzadegan, J., Bahrani, M., & Ghayoomi, M. (2011). Lessons from building a Persian written corpus: Peykare. *Language resources and evaluation*, 45(2), 143-164. <https://doi.org/10.1007/s10579-010-9132-x>.
- Coulthard, M. (2004). Author identification, idiolect, and linguistic uniqueness. *Applied Linguistics*, 25(4), 431-447. <https://doi.org/10.1093/applin/25.4.431>.
- Dabagh, R. M. (2007). Authorship attribution and statistical text analysis. *Advances in Methodology and Statistics*, 4(2), 149-163. <https://doi.org/10.51936/uvjx7198>.
- Darouneh, A. H., & Shariati, A. (2014). Metrics for evaluation of the author's writing styles: Who is the best? *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 24(3). <https://doi.org/10.1063/1.4895468>.
- Dowlatabadi, M. (2016). The elderly people's elapsed time. Tehran: Cheshmeh. (In Persian)
- Dowlatabadi, M. (2022). *Kelidar* (37th print). Tehran: Farhang Moaser. (In Persian)
- Ebrahimi, N. (1995). *A quiet Romance*. Tehran: Rouzbahan. (In Persian)
- Ebrahimi, N. (2020). *On the blue and red paths*. Tehran: Rouzbahan. (In Persian)
- Farahmandpoor, Z., Nikmehr, H., Mansoorizade, M., & Tabibzadeh Ghamsary, O. (2013). A novel intelligent Persian authorship system based on writing style. *Soft Computing Journal*, 1(2), 26-35. <https://dorl.net/dor/20.1001.1.23223707.1391.1.2.60.9> (In Persian)
- Golshaie, R. (2019). Function words as idiolect markers: A corpus-based approach to authorship attribution in Farsi. *Language Related Research*, 10(3), 293-317. (In Persian)
- Golshiri, H. (1971). *Christine and kid*. Tehran: Ketaab-e Zaman. (In Persian)
- Golshiri, H. (1991). *Dar velayat-e Hava*. Stockholm: Asr-e Jadid. (In Persian)
- Golshiri, H. (2021). *Prince Ehtejab* (18th print). Tehran: Niloufar. (In Persian)
- Halliday, M. A. K., & Matthiessen, C. M. M. (2014). *Halliday's introduction to functional Grammar* (4th ed.). Oxon: Routledge.
- Hussein Hama, H., Ali-akbari, N., & Karimi, Y. (2022). Mood and modality in Sorani Kurdish: A functional analysis. *Researches in Western Iranian Languages and Dialects*, 9(4), 1-23. <https://doi.org/10.22126/JLW.2021.6008.1504>. (In Persian)
- Jafari, A. (2008). An analysis of adjuncts in Persian: A syntacto-discoursal approach. *Dastoor*, 5(1), 128-155. (In Persian)
- Mahmoud, A. (1974). *The neighbors*. Tehran: Amirkabir. (In Persian)
- Mahmoud, A. (2002). *The strangers and the little native boy*. Tehran: Moin. (In Persian)
- Mandenhal, T. C. (1887). The characteristics curves of composition science. *Science*, 9(214s), 237-246.
- Martinez-Galicia, J. A., Embarcadero-Ruiz, D., Ríos-Orduña, A., & Gómez-Adorno, H. (2022). Graph-based siamese network for authorship verification. *CLEF 2022 Labs and Workshops, Notebook Papers*. Italy: Bologna.
- Matthiessen, C. M., & Bateman, J. A. (1991). *Text generation and systemic-functional linguistics: Experiences from English and Japanese*. London and New York: Frances Pinter Publishers.

- Mirzaei, A. (2017). Redefining the concepts of dependent and independent clauses according to a functional approach. *Language and Linguistics*, 13(26), 117-132. (In Persian)
- Mirzaei, A. (2018). *An introduction to corpus linguistics*. Tehran: Allameh Tabataba'i University Press. (In Persian)
- Mirzaei, A. (2021). The relationship between polarity and clausal modality in Persian. *Journal of Western Iranian Languages and Dialects*, 9(1), 113-135. <https://doi.org/10.22126/jlw.2020.5372.144>. (In Persian)
- Mirzaei, A., & Safari, P. (2014). Building specialized and general documents in Persian based on the frequency of function and content words. In *proceeding of The 1st National Conference on Corpus Linguistics* (PP. 175-192). Tehran: Neviseh Parsi. (In Persian)
- Mirzaei, A., & Safari, P. (2018). Persian discourse treebank and coreference corpus. In *Proceedings of the eleventh international conference on language resources and evaluation (lrec 2018)*. Japan: Miazaky.
- Najafi, M., & Tavan, E. (2022). Text-to-text transformer in authorship verification via stylistic and semantical analysis. *CLEF 2022 Labs and Workshops, Notebook Papers*. Italy: Bologna.
- Plecháč, P. (2021). Relative contributions of Shakespeare and Fletcher in Henry VIII: An analysis based on most frequent words and most frequent rhythmic patterns. *Digital Scholarship in the Humanities*, 36(2), 430-438. <https://doi.org/10.1093/lrc/fqaa032>.
- Prasad, R., Dinesh, N., Lee, A., Miltsakaki, E., Robaldo, L., Joshi, A., & Webber, B. (2008). The Penn discourse treebank 2.0. In *Proceedings of the Sixth International Language Resources and Evaluation (LREC'08)*. Marrakech, Morocco: EUropean Language Resources Association.
- Radford, A. (2004). *Minimalist syntax: Exploring the structure of English*: Cambridge University Press.
- Refaeilzadeh, P., Tang, L., & Liu, H. (2009). Cross-validation. *Encyclopedia of database systems*, 5, 532-538. Boston: Springer. https://doi.org/10.1007/978-0-387-39940-9_565.
- Sa'edi, Gh. (1998). *Ashoftehan-e Bidarbakhsh*. Tehran: Negah. (In Persian)
- Sa'edi, Gh. (2018). *Stranger in the town*. Tehran: Negah. (In Persian)
- Schütze, H., Manning, C. D., & Raghavan, P. (2008). *Introduction to information retrieval* (Vol. 39, pp. 234-265). Cambridge: Cambridge University Press.
- Segarra, S., Eisen, M., & Ribeiro, A. (2015). Authorship attribution through function word adjacency networks. *IEEE Transactions on Signal Processing*, 63(20), 5464-5478. <https://doi.org/10.1109/TSP.2015.2451111>.
- Shamsfard, M., & Bijankhan, M. (2022). *Text and speech processing for the Persian language: The state of the art and a brief review of the theoretical foundations*. Tehran: Samt. (In Persian)
- Shamsfard, M., Hesabi, A., Fadaei, H., Mansoory, N., Famian, A., Bagherbeigi, S., & Assi, S. M. (2010). Semi automatic development of farsnet: The persian wordnet. In *Proceedings of 5th global WordNet conference* (Vol. 29). India: Mumbai.
- Stamatatos, E. (2009). A survey of modern authorship attribution methods. *Journal of the American Society for Information Science and Technology*, 60(3), 538-556. <https://doi.org/10.1002/asi.21001>
- Teich, E. (1995). *A proposal for dependency in systemic functional grammar-metasemiosis in computational systemic functional linguistics*. Ph.D. Doctoral dissertation, University of the Saarland and GMD/IPS, Darmstadt, Germany.
- Uchendu, A., Le, T., Shu, K., & Lee, D. (2020). Authorship attribution for neural text generation. In *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing* (pp. 8384-8395). (EMNLP 2020-2020 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference). Association for Computational Linguistics (ACL).
- Weerasinghe, J., Singh, R., & Greenstadt, R. (2021). Feature vector difference based authorship verification for open-world settings. In *Proceedings of working of the evaluation Forum* (pp.2201-2207). Romania: Bucharest.