برچسب‌گذاری ادات سخن زبان فارسی با استفاده از مدل شبکهٔ فازی

محمد بادپیما[1]، فاطمه حورعلی[2] و مریم حورعلی*[3]

[1و3] گروه آموزشی برق و کامپیوتر، دانشگاه مالک‌اشتر، تهران، ایران

[2]گروه آموزشی برق و کامپیوتر، مجتمع آموزش عالی اسفراین، خراسان شمالی، ایران

چکیده

برچسب‌گذاری ادات سخن یکی از مسائل مطرح در حوزهٔ پردازش زبان‌های طبیعی است. هدف در این مسئله تعیین نقش واژگان در جمله است. برحسب این برچسب‌گذاری ویژگی‌های دستوری و نحوی واژگان نیز مشخص می‌شود. در این مقاله یک روش مبتنی بر آماری برای ادات سخن فارسی پیشنهاد شده است. در این روش محدودیت‌های روش‌های آماری با استفاده از معرّفی یک مدل شبکهٔ فازی کاهش پیدا کرده است؛ به‌طوری‌که درصورت وجود تعداد کمی دادهٔ آموزشی، مدل فازی پارامترهای قابل اطمینان‌تری را تخمین می‌زند. در این روش ابتدا هنجارسازی به‌عنوان پیش‌پردازش صورت گرفته و سپس فراوانی هر واژه با توجه به برچسب مربوطه به‌صورت یک تابع فازی تخمین زده و سپس مدل شبکهٔ فازی تشکیل شده و درجهٔ هر یال در این شبکه با استفاده از یک شبکهٔ عصبی و تابع عضویت مشخص می‌شود. درنهایت بعد از این‌که مدل شبکهٔ فازی برای یک جمله ساخته شد، از الگوریتم ویتربی برای تعیین محتمل‌ترین مسیر در این شبکه استفاده شده است. نتایج آزمایش روی پیکرهٔ بی‌جن‌خان کارایی این روش را تأیید کرده و نشان می‌دهد که روش پیشنهادی در شرایطی که داده‌های آموزشی کم‌تری در اختیار باشد، از روش‌های مشابه، مثل مدل مخفی مارکوف عملکرد بهتری دارد.

واژگان کلیدی: پردازش زبان‌های طبیعی، برچسب‌زنی اجزای سخن، زبان فارسی، فازی، شبکهٔ عصبی.

Part Of Speech Tagging of Persian Language using Fuzzy Network Model

Mohammad Badpeima[1], Fatemeh Hourali[2] & Mayam Hourali*[3]

[1,3] Electrical and Computer Engineering Department, MUT, Tehran, Iran

[2]Electrical and Computer Engineering Department, Esfarayen University Of Technology, North Khorasan, Iran

Abstract

Part of speech tagging (POS tagging) is an ongoing research in natural language processing (NLP) applications. The process of classifying words into their parts of speech and labeling them accordingly is known as part-of-speech tagging, POS-tagging, or simply tagging. Parts of speech are also known as word classes or lexical categories. The purpose of POS tagging is determining the grammatical category of the words in a sentence. Grammatical and syntactical features of words are determined based on these tags.

The function of existing tagging methods depends on the corpus. As if the educational and test data are extracted from a corpus, the methods are well-functioning, or if the number of educational data is low, especially in probabilistic methods, the accuracy level also decreases. The words used in sentences are often vague. For example, the word 'Mahrami' can be a noun or an adjective. Existing ambiguity can be eliminated by using neighbor words and an appropriate tagging method.

Methods in this domain are divided into several categories such as: based on memory [2], rule based methods [5], statistical [6], and neural network [7]. The precision of more of these methods is an average of

* Corresponding author

*نویسندهٔ عهده‌دار مکاتبات • تاریخ ارسال مقاله: ۱۳۹۵/۹/۳۱ • تاریخ آخرین بازنگری: ۱۳۹۷/۷/۱۴ • تاریخ پذیرش: ۱۳۹۷/۱۰/۱۹

[DOI: 10.29252/jsdp.15.4.123]

95% [1]. In the paper [13], using the TnT probabilistic tagging and smoothing and variations on the estimation of the three-words likelihood function, a tagging model has been created that has reached 96.7% in total on the Penn Treebank and NEGRA entities. [14] Using the representation of the dependency network and extensive use of lexical features, such as the conditional continuity of the sequence of words, as well as the effective use of the foreground in the linear models of linear logarithms and fine-grained modeling of the unknown words, on the Penn Treebank WSJ model, 97.24% accuracy is achieved.

The first work in Farsi that has used the word neighborhoods and the similarity distribution between them. The accuracy of the system is 57.5%. In [19], a Persian open source tagger called HunPoS was proposed. This tag uses the same TnT method based on the Hidden Markov model and a triple sequence of words, and 96.9% has reached on the "Bi Jen Khan" corpus.

In this paper a statistical based method is proposed for Persian POS tagging. The limitations of statistical methods are reduced by introducing a fuzzy network model, such that the model is able to estimate more reliable parameters with a small set of training data. In this method, normalization is done as a preprocessing step and then the frequency of each word is estimated as a fuzzy function with respect to the corresponding tag. Then the fuzzy network model is formed and the weight of each edge is determined by means of a neural network and a membership function. Eventually, after the construction of a fuzzy network model for a sentence, the Viterbi algorithm as s subset of Hidden Markov Model (HMM) algorithms is used to specify the most probable path in the network.

The goal of this paper is to solve a challenge of probabilistic methods when the data is low and estimation made by these models is mistaken.

The results of testing this method on ``Bi Jen Khan'' corpus verified that the proposed method has better performance than similar methods, like hidden Markov model, when fewer training examples are available. In this experiment, several times the data is divided into two groups of training and test with different sizes ascending. On the other hand, in the initial experiments, we reduced the train data size and, in subsequent experiments, increased its size and compared with the HMM algorithm.

As shown in figure 4, the train and test set and are directly related to each other, as the error rate decreases with increasing the training set and vice versa. In tests, three criteria involving precision, recall and F1 have been used. In Table 4, the implementation of HMM models and a fuzzy network is compared with each other and the results are shown.

Keywords: Natural language processing, Part of speech (POS) tagging, Persian language, Fuzzy, Neural network.

۱- مقدمه

برچسب‌زنی اجزای سخن یکی از مهم‌ترین مسائل مطرح در پردازش زبان‌های طبیعی است. عملکرد روش‌های برچسب‌زنی موجود وابستگی زیادی به پیکرهٔ مورد استفاده دارد. به‌طوری‌که اگر داده‌های آموزشی و آزمون از یک پیکره استخراج شده باشند، روش‌ها عملکرد خوبی دارند یا اگر تعداد دادهٔ آموزشی کم باشد به‌خصوص در روش‌های احتمالی میزان دقّت نیز کاهش می‌یابد [1]. برچسب‌زنی واژگان کار دشواری است؛ به‌دلیل این‌که اگر داده‌های آزمون از یک پیکرهٔ دیگری انتخاب شده باشند، عملکرد سامانه به‌طورمعمول مطلوب نخواهد بود. نحوهٔ برخورد با واژگانی که در داده‌های آموزشی وجود نداشتند و برای نخستین‌بار دیده می‌شوند نیز یکی دیگر از چالش‌های این حوزه است. برچسب‌زنی واژگان در حجم نمایه‌سازی و بازیابی اطلاعات نقش مهمی دارد. علاوه‌براین برچسب‌گذاری یک ابزار تحلیل نحوی بوده و هم‌چنین به‌عنوان یک روش مناسب برای ابهام‌زدایی به‌شمار می‌آید [1]. واژگانی که در جملات استفاده می‌شوند، اغلب مبهم هستند. به‌عنوان مثال واژهٔ «محرمی» می‌تواند اسم یا صفت باشد. ابهام موجود را می‌توان با استفاده از واژگان همسایه و یک روش برچسب‌زنی مناسب برطرف کرد. روش‌های موجود در این حوزه به چند دسته مبتنی بر حافظه [2]، مبتنی بر قانون [5]، آماری [6] و شبکهٔ عصبی [7] تقسیم می‌شوند. دقت بیشتر این روش‌ها به‌صورت میانگین ۹۵درصد است [1]. در مقاله [13] با استفاده از برچسب‌زنی مدل احتمالاتی TnT و هموارسازی و تغییراتی روی تخمین تابع احتمال سه‌واژه‌ای‌ها مدل برچسب‌زنی ایجاد شده که روی پیکرهٔ Penn Treebank و NEGRA درمجموع به‌دقت ۹۶/۷ درصد دست یافته است. در [14] با استفاده از بازنمایی شبکهٔ وابستگی و استفادهٔ گسترده از ویژگی‌های واژگانی همانند پیوستگی شرطی دنباله‌ای از واژگان و هم‌چنین استفادهٔ مؤثر از مقدم در مدل‌های شرطی لگاریتم خطی و مدل‌سازی ریزدانه از ویژگی‌های واژگان ناشناخته، به‌دقت ۹۷/۲۴ درصد روی پیکرهٔ Penn Treebank WSJ رسیده است. در [15] با استفاده از ماشین بردار پشتیبان مدل مؤثر و کارآمدی پیشنهاد شده که روی پیکرهٔ Wall Street Journal به‌دقّت

[DOI: 10.29252/jsdp.15.4.123]

۹۷/۱۶ درصد دست یافته است. در [16] از ویژگی ساخت‌واژی واژگان ناشناخته استفاده شده و دقّت برچسب‌زنی این واژگان را به هشتاددرصد بهبود داده است درضمن آزمایش‌های روی پیکرهٔ Chinese Treebank صورت گرفته است. در مقاله [17] با استفاده از trigram ساده برای تخمین احتمالات استفاده شده و یک برچسب‌زن کدباز با نام HunPos ارائه شده که دقت آن روی پیکره Penn Treebank WSJ در بهترین حالت ۹۶/۵۸ درصد است. [18] نخستین کار در زبان فارسی است که از همسایگی واژگان و توزیع شباهت آن‌ها استفاده کرده و دقّت این سامانه ۵۷,۵ درصد است. در [19] یک برچسب‌زن فارسی کدباز به نام HunPoS ارائه شده و از همان روش TnT برمبنای مدل مخفی مارکوف و دنباله سه‌تایی از واژگان استفاده کرده و به‌دقّت ۹۶/۹ درصد روی پیکرهٔ بی‌جن‌خان رسیده است.

برچسب‌زنی ادات سخن زبان فارسی چالش‌های خاص خود را دارد که ازجمله آن‌ها می‌توان به مواردی که در ادامه آمده اشاره کرد. شناسایی واژه‌های ناشناخته در متن و مشکلات خط فارسی، وجود "وند"های بسیار که به‌طورمعمول به واژه می‌چسبند و باعث به‌وجودآمدن مشکلاتی برای واژگان با ریشه یکسان می‌شوند، مشکلاتی که شکل یکسان برخی تکواژها ایجاد می‌کنند، برخی از تکواژها همراه با واژگان یا افعال می‌توانند دست‌کم به سه شکل مختلف ظاهر شوند که خود این مسئله عامل تأثیرگذار در برچسب‌گذاری است و هم‌چنین موارد دیگری که در این‌جا به‌صورت گزینشی به برخی از آن‌ها اشاره شد. مسئلهٔ برچسب‌گذاری ادات سخن نه‌تنها در شناسایی نقش واژگان مبهم تأثیر دارد، بلکه در کاربردهایی مانند سنتز و تشخیص گفتار، ترجمهٔ ماشین، بازیابی اطلاعات و غیره نقش مهمّی را ایفا می‌کند. از یک دیدگاهی دیگر متدهای موجود برای حل این مسئله به دو دسته برچسب‌زنی درشت‌دانه و ریزدانه تقسیم می‌شوند که در دستهٔ ریزدانه نقش واژگان به‌صورت دقیق مشخص می‌شود. به‌عنوان مثال اگر واژه‌ای صفت تشخیص داده شود، نوع صفت در ریزدانه مشخص می‌شود. روش پیشنهادی در این مقاله از دستهٔ ریزدانه بوده و از ترکیب روش‌های آماری، شبکهٔ عصبی و شبکهٔ فازی تشکیل شده است. این مقاله دو نقطه قوت دارد. یکی شناسایی واژگان ناشناخته و دیگری رسیدن به نتایج مطلوب با توجه به داده آموزشی پائین می‌باشد.

شکل (۱) فرایند روش پیشنهادی را نشان می‌دهد. در روش پیشنهادی ابتدا هنجارسازی ساده صورت می‌گیرد، به این صورت که تمام پسوندهای جمع‌کننده به خود واژه چسبیده می‌شوند؛ سپس بر اساس تمام برچسب‌هایی که واژگان می‌توانند داشته باشند، یک گراف پایه ساخته و سپس با استفاده از توابع عضویت فازی و شبکه عصبی وزن‌هایی برای هر یک از گره‌ها و یال‌ها اختصاص داده می‌شود. درنهایت این گراف وزن‌دار که به مدل شبکهٔ فازی معروف است به الگوریتم ویتربی [4] داده می‌شود سپس این الگوریتم محتمل‌ترین مسیر را انتخاب می‌کند.

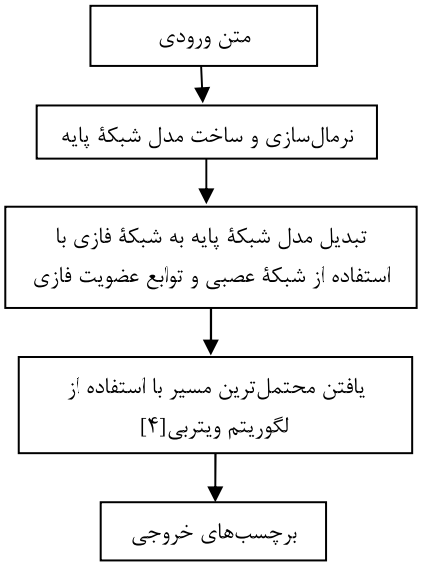

(شکل-۱): فرایند روش پیشنهادی
(figure-1): Process of proposed method

این روش روی مجموعه‌دادهٔ بی‌جن‌خان [3] مورد آزمایش قرار گرفته و نتایج نشان‌دهندهٔ این است که وقتی داده‌های آموزشی کمی در اختیار داشته باشیم، این روش بهتر از مدل مخفی مارکوف مرتبهٔ نخست عمل می‌کند. ساختار مقاله به‌صورت زیر است:

درادامهٔ مقاله و در بخش دوم شبکهٔ فازی تعریف می‌شود. در بخش سوم نحوهٔ ساخت شبکهٔ فازی برای برچسب‌زنی ادات سخن فارسی بررسی شده است. در بخش چهارم نتایج آورده شده و بخش پنجم نیز شامل نتیجه‌گیری است.

۲- شبکهٔ فازی

شبکه‌های فازی در میدان‌های مختلف فناوری و صنعت کاربرد دارد که از جملهٔ آن‌ها می‌توان به پیش‌بینی [8]، سامانه‌های پشتیبانی تصمیم [9] و پیداکردن بیشینهٔ جریان [10] اشاره کرد. تعریف شبکهٔ فازی به‌شدت به حوزهٔ استفاده

[DOI: 10.29252/jsdp.15.4.123]

آن بستگی دارد. در اینجا یک تعریف جدیدی از شبکهٔ فازی با توجه به زمینهٔ کاری موردنظر، ارائه شده است. یک شبکه، گرافی جهت‌دار با وزن‌هایی روی لبه‌های آن است [11]. برای بازی‌سازی این شبکه می‌توان از همان روش فازی‌سازی روابط گراف‌ها در [12] استفاده کرد که به شبکهٔ حاصل از این فازی‌سازی، شبکهٔ فازی گفته می‌شود.

فرض کنید G=(V,E) یک گراف جهت‌دار است که در آن V و E به‌ترتیب نشان‌دهندهٔ گره‌ها و یال‌ها باشند؛ در این صورت برای تعریف شبکهٔ فازی می‌توان فرض کرد که V یک زیرمجموعه‌ای از ضرب W*T است که در آن W و T به‌ترتیب نشان‌دهندهٔ واژگان و برچسب‌ها هستند. در این صورت گره‌های فازی می‌تواند به‌صورت رابطه (۱) تعریف شود که در آن $\mu_{\tilde{V}}(w,t)$ نشان‌دهندهٔ تابع عضویت است.

$$\tilde{V}=\left\{\left((w,t),\mu_{\tilde{V}}(w,t)\right)\middle|(w,t)\in W\times T\right\} \qquad (۱)$$

هم‌چنین می‌توان فرض کرد که E یک زیرمجموعه‌ای از ضرب $V\times V$ است. در این صورت یال‌های فازی می‌تواند توسط رابطه (۲) تعریف شود. $\mu_{\tilde{V}}(v_i,v_j)$ یک تابع عضویت از (v_i,v_j) است.

$$\tilde{E}=\left\{\left((v_i,v_j),\mu_{\tilde{V}}(v_i,v_j)\right)\middle|(v_i,v_j)\in V\times V\right\} \qquad (۲)$$

بدین ترتیب شبکهٔ فازی $\tilde{G}$ ساخته می‌شود.

مجموعه‌دادهٔ بی‌جن‌خان دارای چهل برچسب بوده و حدود ۲/۶ میلیون واژه برچسب خورده است. بسیاری از این واژگان در این مجموعه‌داده بیش از یک برچسب دارند که آمار دقیق آن در جدول (۱) آورده شده است.

(جدول-۱): تعداد برچسب‌های متفاوت

(Table-1): Number of different labels

تعداد واژگان	تعداد برچسب‌های متفاوت
۶۲۵۶۸	۱
۴۸۳۸	۲
۴۹۳	۳
۱۱۸	۴
۴۹	۵
۱۴	۶
۷	۷
۲	۸
۲	۹
۱	۱۰

به‌عنوان مثال اگر مجموعه $\tilde{V}$ به‌صورت زیر باشد.

$$\tilde{V}=\left\{\begin{array}{l}((\#/DELM),0.1),((\text{اولین}/ADJ\_SIM),1.0),((\text{سیاره}/ADJ\_SIM),1.0),\\((\text{سیاره}/N\_SIGN),1.0),((\text{سیاره}/P),1.0),((\text{منظومه}/N\_SIGN),1.0),\\((\text{شمسی}/N\_SIGN),1.0),((\text{شمسی}/ADJ\_SIM),1.0),((\text{است}/V\_PRE),1.0),\\((./DELM),1.0)\end{array}\right\}$$

و اگر مجموعه یال‌های فازی $\tilde{E}$ به‌صورت زیر باشد.

$$\tilde{E}=\left\{\begin{array}{l}((\#/DELM),(\text{اولین}/ADJ\_SUP),1.0),((\text{اولین}/ADJ\_SUP),(\text{سیاره}/ADJ\_SIM),0.4),\\((\text{اولین}/ADJ\_SUP),(\text{سیاره}/N\_SIGN),0.7),((\text{اولین}/ADJ\_SUP),(\text{سیاره}/P),0.2),\\((\text{سیاره}/ADJ\_SIM),(\text{منظومه}/N\_SIGN),0.26),((\text{سیاره}/SIGN),(\text{منظومه}/N\_SIGN),0.8),\\((\text{سیاره}/P),(\text{منظومه}/N\_SIGN),0.3),((\text{منظومه}/N\_SIGN),(\text{شمسی}/N\_SIGN),0.5),\\((\text{منظومه}/N\_SIGN),(\text{شمسی}/ADJ\_SIM),0.7),((\text{شمسی}/ADJ\_SIM),(\text{است}/V\_PRE),0.6),\\((\text{است}/V\_PRE),(\times/DELM),1.0),((\text{سیاره}/N\_SIGN),1.0)\end{array}\right\}$$

شبکهٔ فازی حاصل از دو مجموعه در شکل (۲) نشان داده شده که محتمل‌ترین مسیر با خطوط پررنگ مشخص شده است.

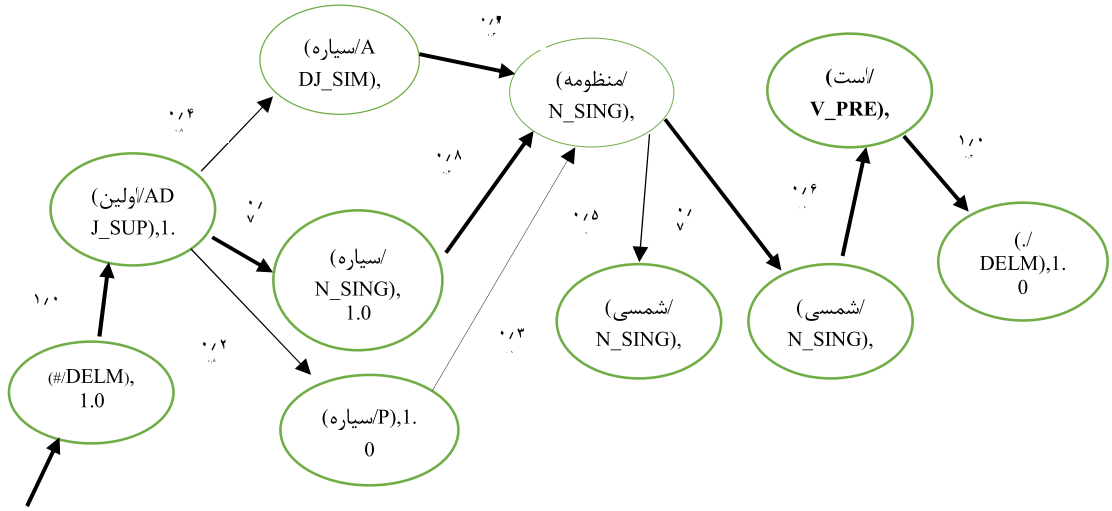

(شکل-۲): مثالی از شبکهٔ فازی برای عبارت موردنظر

(Figure-2): An example of a fuzzy network for a given phrase

[DOI: 10.29252/jsdp.15.4.123]

۳- ساخت شبکهٔ فازی برای برچسب‌زنی ادات سخن

فرض کنید زبان فارسی مجموعه متناهی از واژگان W و برچسب‌ها T به‌صورت روابط (۳) باشد:

$$W = \{w^1, w^2, w^3, \ldots, w^N\}$$
$$T = \{t^1, t^2, t^3, \ldots, t^M\} \quad (۳)$$

که N و M در اینجا به‌ترتیب نشان‌دهندهٔ تعداد واژگان و برچسب‌ها است. رابطه (۴) [20] تابع عضویت مربوط به هر گره است که در آن $w \in W$ و $t \in T$ می‌باشد. برای تخمین این تابع عضویت از احتمال رخدادن واژه W با برچسب t، استفاده می‌شود. صورت کلی این احتمال در رابطهٔ (۵) [20] نشان داده شده است.

$$\mu_{\vec{v}}(w,t) = \begin{cases} \sqrt[k]{\Pr(t|w)}, & \Pr(t|w) > 0 \\ 1, & O.W \end{cases}, \quad k \simeq ۰.۹ \quad (۴)$$

$$\Pr(t|w) = \frac{C(w,t)}{\sum_t C(w,t)} \quad (۵)$$

در رابطهٔ (۴) هنگامی‌که یک واژه در پیکرهٔ آموزشی وجود داشته باشد، مقدار آن مطابق رابطه $\sqrt[k]{\Pr(t|w)}$ محاسبه می‌شود، در غیراین‌صورت زمانی که واژه‌ای در پیکرهٔ آموزشی نباشد، برای آن مقدار یک را برمی‌گرداند. از پارامتر k هم برای کنترل گرادیان استفاده می‌شود و در آزمایش‌ها مقدار ثابت ۰/۹ را دارد. $C(w,t)$ در رابطه (۵) نیز نشان‌دهندهٔ تعداد واژه W با هر برچسبی در مجموعه داده آموزشی است.

برای تعیین وزن یال‌ها یا همان توالی مجاز برچسب‌ها که به قواعد دستوری زبان مربوط می‌شود از شبکهٔ عصبی استفاده شده است. به‌عنوان مثال اگر توالی برچسب‌ها به‌صورت زیر باشد:

X={DELM,ADJ_SIM,ADJ_SUP,N_SING,…,DELM}

در این صورت این مجموعه توالی را به بردار عددی تبدیل می‌کنیم که نتیجه حاصل از این تبدیل یک بردار دودویی به‌صورت زیر خواهد بود. طول این بردار با توجه به تعداد برچسب‌های استفاده‌شده در مجموعه‌دادهٔ بی‌جن‌خان، چهل است.

$$X = \{0, 0, 1, 0, \ldots, 0\}$$

ساختار شبکه نیز با توجه به مجموعه‌دادهٔ مورداستفاده، ساخته شده است. به همین دلیل ورودی و خروجی این شبکه با توجه به تعداد برچسب‌های استفاده‌شده در دادهٔ بی‌جن‌خان دارای چهل نرون است؛ درضمن دو لایهٔ مخفی در هر لایه سه نرون در نظر گرفته شده و از تابع پرسپترون در آزمایش‌ها استفاده شده است. ساختار کلی شبکه در شکل (۳) قابل مشاهده است. در این روش از مرتبه نخست مدل مخفی مارکوف استفاده شده است. در مرتبه یک توالی برچسب‌ها فقط یکی از این نرون‌ها فعال و مابقی غیرفعال هستند. شبکه با توجه به وزن‌های آموزش‌دیده چهل مقدار را در خروجی ظاهر می‌کند که این مقادیر به‌دست‌آمده به‌عنوان خروجی شبکهٔ عصبی به تابع عضویت (۶) [20] داده می‌شود. این تابع عضویت یک مقداری بین صفر و یک برمی‌گرداند. به‌عنوان مثال این خروجی با توجه به بردار ورودی X با مقدار فعال ADJ_SUB به این معنی است که بعد این برچسب، کدام برچسب می‌تواند ظاهر شود. yها خروجی‌های شبکه هستند. $y_{\max}, y_{\min}$ مقدار کمینه و بیشینه خروجی شبکه و β نیز مقدار ثابت ۰/۹ دارد.

$$\mu_E(w,t) = \frac{y_j - \beta . y_{\min}}{y_{\max} - \beta . y_{\min}} \quad (۶)$$

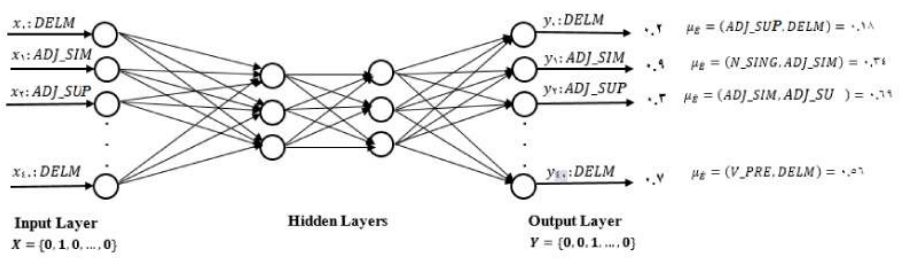

(شکل-۳): ساختار شبکه عصبی برای تخمین وزن یال‌ها

(Figure-3): Neural network structure to estimate the weight of the edges

[DOI: 10.29252/jsdp.15.4.123]

شبکهٔ عصبی قواعد دستور زبان مربوطه را یاد گرفته و به‌صورت مطلوب با ابهامات برخورد می‌کند. تبدیل بردار توالی برچسب‌ها برای یک جمله به بردار دودویی باعث می‌شود که تعداد حالت‌های زیادی از قواعد دستور زبان تولید شود.

در ادامه مثالی از روند کار، ارائه شده است. البته در این مثال برای سادگی و واضح‌ترشدن روند کار فرض شده که پیکرهٔ بی‌جن‌خان دارای شش برچسب و درنتیجه شبکه عصبی هم دارای شش نورون در ورودی و خروجی است.

با این مفروضات جمله "تهران پایتخت ایران است." را در نظر بگیرد و فرض کنید که این جمله را بخواهیم با شش برچسب، برچسب‌گذاری کنیم و هم‌چنین فرض کنید که برای واژه "پایتخت" دو برچسب L_6, L_5 مشخص شده و بقیه واژگان نیز یک برچسب داشته باشند. در این صورت مجموعه برچسب‌های واژگان جمله به‌صورت زیر خواهد بود:

$$\{(\text{تهران}/L_5),(\text{ایران}/L_1),(\text{است}/L_3),(\text{است}/L_4),(\text{پایتخت}/L_5,L_6),(\text{.}/L_6)\}$$

بنابراین تعداد قواعدی که ازجمله مربوطه به‌عنوان داده آموزشی برای شبکهٔ عصبی می‌توان تولید کرد بر طبق جدول (۲) است.

(جدول-۲): نحوه تولید داده‌های آموزشی برای شبکه عصبی

(Table-2): How to generate educational data for the neural network

Input(Data)		Output(Label)	
$\{L_1,L_2,L_3,L_4,L_5,L_6\}$		$\{L_1,L_2,L_3,L_4,L_5,L_6\}$	
L_5, تهران	{0,0,0,0,1,0}	L_2, پایتخت	{0,1,0,0,0,0}
L_2, پایتخت	{0,1,0,0,0,0}	L_1, ایران	{1,0,0,0,0,0}
L_1, ایران	{1,0,0,0,0,0}	L_3 , است	{0,0,1,0,0,0}
L_3 , است	{0,0,1,0,0,0}	L_4 , است	{0,0,0,1,0,0}
L_4 , است	{0,0,0,1,0,0}	., L_6	{0,0,0,0,0,1}

بعدازاین‌که وزن گره‌ها و یال‌های شبکه تعیین شد از الگوریتم ویتربی برای تعیین محتمل‌ترین استفاده می‌کنیم.

۴ - نتایج آزمایش‌ها

روش پیشنهادی روی داده‌های بی‌جن‌خان مورد آزمایش قرار گرفت.

در جدول (۳) نیز فراوانی برچسب‌ها برحسب درصد آورده شده است. در این جدول هشت برچسب به‌صورت مجزا با درصد بیان شده و برچسب‌های باقی‌مانده همان‌طور که در سطر آخر قابل مشاهده است، حدود دوازده درصد را به خود اختصاص دادند. در این آزمایش چندین‌بار داده‌ها به دو دستهٔ آموزشی و آزمایشی با اندازه‌های مختلف به‌صورت صعودی تقسیم شده‌اند. به‌عبارت‌دیگر در آزمایش‌های اولیه اندازه داده آموزشی را کمتر در نظر گرفتیم و در آزمایش‌های بعدی اندازه آن را افزایش داده و با الگوریتم HMM مقایسه کردیم که نتایج در شکل (۴) نشان داده شده است.

(جدول-۳): توزیع برچسب‌ها

(Table-3): Distribute labels

TAGS	Percentage distribution
N_SING	۳۸٪
P	۱۲٪
DELM	۱۰٪
ADJ_SIM	۹٪
CON	۸٪
N_PL	۶٪
N_PA	۳٪
PRO	۲٪
and etc.	۱۲٪

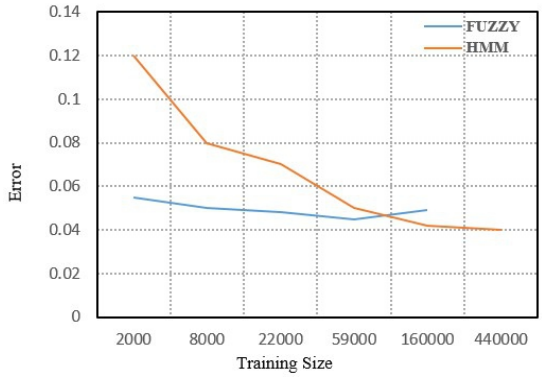

(شکل-۴): نتایج مقایسهٔ فازی و مدل مخفی مارکوف برای مرتبهٔ نخست

(Figure-4): Compare Fuzzy Results and Hidden Markov Model for First Order

همان‌طور که در نمودار مشخص است، مجموعهٔ آموزشی و خطا با هم‌دیگر رابطهٔ مستقیم دارند؛ به‌طوری‌که با افزایش مجموعهٔ آموزشی، خطا کاهش و با کاهش آن خطا زیاد می‌شود.

در آزمایش‌ها از سه معیار دقّت، فراخوانی و F1 استفاده شده و روش محاسبه این سه معیار به‌صورت زیر است:

$$P = \frac{M}{N} \quad (۷)$$

$$R = \frac{M}{L} \quad (۸)$$

$$F_1 = \frac{2\times P\times R}{P+R} \quad (۹)$$

[DOI: 10.29252/jsdp.15.4.123]

که در این‌جا M, N به‌ترتیب تعداد کل برچسب‌های اختصاص‌داده‌شده و تعداد برچسب‌های صحیح اختصاص داده‌شده توسط مدل است. هم‌چنین L تعداد کل برچسب‌های موجود در داده استاندارد است. در جدول (۴) پیاده‌سازی دو مدل HMM و شبکهٔ فازی باهم مقایسه شده و نتایج نشان داده شده‌اند.

(جدول-۴): ارزیابی مدل مخفی مارکوف و شبکه‌های فازی
(Table-4): Evaluation of Hidden Markov Model and Fuzzy Networks

روش	دقت	فراخوان	F1
HMM	76%	80%	78%
Fuzzy Network	84%	81%	82%

۵- نتیجه‌گیری و کارهای آینده

مسئلهٔ برچسب‌گذاری ادات سخن نه‌تنها در شناسایی نقش واژگان مبهم تأثیر دارد، بلکه در کاربردهایی مانند سنتز و تشخیص گفتار، ترجمهٔ ماشین، بازیابی اطلاعات و غیره نقش مهمی را ایفا می‌کند. درواقع هدف، تعیین نقش واژگان در جمله است. برحسب این برچسب‌گذاری، ویژگی‌های دستوری و نحوی واژگان نیز مشخص می‌شود.

در این مقاله یک روش مبتنی بر شبکهٔ فازی ارائه شده است. در این روش برخی از چالش‌های روش‌های احتمالی بررسی و سپس از شبکه‌های عصبی و مدل شبکهٔ فازی برای رفع این چالش‌ها استفاده شده است. در این روش محدودیت‌های روش‌های آماری با استفاده از معرفی یک مدل شبکهٔ فازی کاهش پیدا کرده است؛ به‌طوری‌که درصورت وجود تعداد کمی دادهٔ آموزشی مدل فازی پارامترهای قابل اطمینان‌تری را تخمین می‌زند؛ درواقع این مقاله دو نقطه قوت دارد. یکی شناسایی واژگان ناشناخته و دیگری رسیدن به نتایج مطلوب با توجه به دادهٔ آموزشی پایین است. روش ارائه‌شده می‌تواند در شرایطی که اندازه دادهٔ آموزشی کم باشد، کارایی بهتری داشته باشد.

نتایج آزمایش روی پیکرهٔ بی‌جن‌خان کارایی این روش را تأیید کرده و نشان می‌دهد که روش پیشنهادی در شرایطی که داده‌های آموزشی کمتری در اختیار باشد، از روش‌های مشابه، مثل مدل مخفی مارکوف، عملکرد بهتری دارد.

در کارهای آینده برای حل این مسئله می‌توان از شبکه‌های عصبی بازگشتی یا ساختارهای یادگیری عمیق استفاده کرد.

۶- مراجع 6- References

[۱]محمدرضا فیضی درخشی، فرهنگ فیروزی، مهدی رحیمی،"مقایسه کارهای انجام‌شده برای برچسب‌گذاری ادات سخن زبان فارسی"، زبان‌شناسی رایانشی، سومین همایش ملی زبان‌شناسی رایانشی، دانشگاه صنعتی شریف، ۱۳۹۳.

[1] M. R. Feizi Derakhshi, F. Firozi, M. Rahimi, "Comparison of Works Performed on the Persian Part-of-Speech Tagging," *Computational Linguistics, 3rd National Conference on Computer Linguistics*, Sharif University of Technology, 2014.

[۲]مهدی حسینی، سیستم برچسب‌گذاری و ابهام‌زدایی خودکار اجزای کلام برای پیکره متنی زبان فارسی، کارشناسی ارشد، علم و صنعت، تهران، ۱۳۸۷.

[2] M. Hosseini, "Automatic labeling system and automatic disambiguation of the components of the word for the textual form of Persian language," MA, Iran University of Science And Technology, Tehran, 2008.

[3] M. BijanKhan, "The Role of the Corpus in Writing a Grammar: An Introduction to a Software", *Iranian Journal of Linguistics*, 19(2), 2004.

[4]G. D. Forney, "The Viterbi algorithm," *Proceedings of the IEEE*, pp. 268-278, 1973.

[5]E. Brill, "A simple rule-based part of speech tagger", In *Proceedings of the 3rd Conference on Applied Natural Language Process-ing(ANLP-92)*, pp. 153-155, 1992.

[6]K. W. Church, "A stochastic PARTS program and noun phrase parser for unrestricted text", In *Proceedings of Applied Natural Language Processing*, pp. 136-143, 1988.

[7]J. Benello, A. W. Mackie , and J. A. Anderson , "Syntactic category disambiguation with neural networks," *Computer Speech and Language*, vol.3, pp.203-217, 1989.

[8]H. Hidekiyo and Y. Nishkawa, "Fuzzy network technique for technological forecast-ing", Fuzzy Sets and Systems, pp. 99-113, 1984.

[9]H. Kawamura, "Fuzzy network for decision support systems", Fuzzy Sets and Systems, pp. 59-72, 1993.

[10] S. Chanas and, W. Kolodziejczyk, "Maximum flow in a network with fuzzy arc capacities", Fuzzy Sets and Systems, pp. 165-173, 1982.

[DOI: 10.29252/jsdp.15.4.123]

[11] R. Sedgewick, "Algorithms in C," Addison-Wes-ley Publishing Company, 1990.

[12] H.-J. Zimmermann , "Fuzzy Set Theory and Its Applications, " Kluwer-Nijhoff Publishing, pp. 61-82, 1985.

[13] T. Brants, "TnT – a statistical partof-speech tagger," In *Proceedings of the 6th Conference on Applied Natural Language Processing*, 2000, pages 224–231.

[14] K. Toutanova, D. Klein, Ch. D. Manning and Y. Singer, "Feature-Rich Part-of-Speech Tagging with a Cyclic Dependency Network", 2003,

[15] J. Giménez, and L. Màrquez, "A general pos tagger generator based on support vector machines, " In *Proceedings of the 4th International Conference on Language Resources and Evaluation (LREC 2004)*, Lisbon, Portugal.

[16] H. Tseng, D. Jurafsky, and Ch. Manning. "Morphological features help POS tagg-ing of unknown words across language varieties, " *Fourth SIGHAN Work-shop on Chinese Language Processing*, 2005, pp. 32-39.

[17] P. Hal acsy, A. Kornai, and C. Oravecz, "HunPos – an open source trigram tagger, ", In *Proceedings of the 45th Annual Meeting of the Association for Com-putational Linguistics*, Posters Prague, Czech Republic, 2007.

[18] S. Mostafa ASSI and M. Haji Abdolhosseini, "Grammatical Tagging of a Persian Corpus," Institute for Humanities and Cultural Studies, 2000.

[19] S. Mojgan, "A Statistical Part-of-Speech Tagger for Persian," Department of Linguistics and Philology, NODALIDA 2011, Riga, Latvia, May 11–13, 2011.

[20] K. Jae-Hoon, and G. Chang Kim, "Fuzzy network model for part-of-speech tagging under small training data," *Natural Language En-gineering* 2.02 (1996), pp. 95-110.

محمد بادپیما مدرک کارشناسی خود را در رشتهٔ مهندسی نرم‌افزار از دانشگاه زنجان در سال ۱۳۹۲ و مدرک کارشناسی ارشد خود را در سال ۱۳۹۵ از دانشگاه صنعتی مالک اشتر اخذ کرده است.

زمینه‌های پژوهشی مورد علاقهٔ ایشان عبارتند از: پردازش تصویر و ویدئو، بینایی کامپیوتر، بازشناسی الگو و شبکه‌های عصبی.

نشانی رایانامهٔ ایشان عبارت است از:

badpeima_mohammad@mut.ac.ir

فاطمه حورعلی مدرک کارشناسی خود را در رشتهٔ مهندسی برق از دانشگاه صنعتی شاهرود در سال ۱۳۸۵ و مدرک کارشناسی ارشد خود را در سال ۱۳۸۸ از دانشگاه صنعتی سهند تبریز اخذ کرده است. ایشان در حال حاضر عضو هیئت علمی رشته مهندسی برق مجتمع آموزش عالی اسفراین است. زمینه‌های پژوهشی مورد علاقهٔ ایشان عبارتند از: پردازش تصویر و ویدئو، بینایی کامپیوتر، بازشناسی الگو و شبکه‌های عصبی.

نشانی رایانامهٔ ایشان عبارت است از:

Hourali@esfarayen.ac.ir

مریم حورعلی مدرک کارشناسی ارشد خود را در رشتهٔ مهندسی فناوری اطلاعات، گرایش تجارت الکترونیک از دانشگاه علم و صنعت ایران در سال ۱۳۸۵ و مدرک دکترای خود را در گرایش مهندسی فناوری اطلاعات از دانشگاه تربیت مدرس اخذ کرده است. ایشان در حال حاضر عضو هیئت علمی رشتهٔ هوش مصنوعی دانشگاه صنعتی مالک اشتر تهران است. زمینه‌های پژوهشی مورد علاقهٔ ایشان عبارتند از: پردازش متن و زبان طبیعی، تحلیل اطلاعات در شبکه‌های اجتماعی و سامانه‌های فازی

نشانی رایانامهٔ ایشان عبارت است از:

Mhourali@mut.ac.ir

[DOI: 10.29252/jsdp.15.4.123]