



# تشخیص موجودیت‌های نامدار در متون فارسی با استفاده از یادگیری عمیق

سعیده ممتازی<sup>\*</sup> و فرزانه ترابی

دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی امیرکبیر، تهران، ایران

## چکیده

شناسایی موجودیت‌های نامدار<sup>۱</sup> یکی از فعالیت‌های زیربنایی در حوزه پردازش زبان طبیعی<sup>۲</sup> و به طور کلی زیرمجموعه‌ای از استخراج اطلاعات<sup>۳</sup> است. در فرآیند شناسایی موجودیت‌های نامدار به دنبال یافتن عناصر اسمی در متن و دسته‌بندی آنها به رده‌هایی از بیش تعیین-شده از قبیل اسامی اشخاص، سازمان‌ها، مکان‌ها، مذاهب، عنوان کتاب‌ها، عنوان فیلم‌ها و غیره هستیم. در این مقاله با بهره‌گیری از روش‌های نوین در این حوزه مانند استفاده از دو بُردار مختلف بازنمای معنایی واژگان بر مبنای واژه و حروف تشکیل دهنده آن بر مبنای شبکه‌های عصبی و همچنین استفاده از روش‌های یادگیری عمیق<sup>۴</sup> یک سامانه تشخیص موجودیت‌های نامدار معرفی می‌شود؛ همچنین در راستای پژوهش حاضر، یک پیکره برچسب‌گذاری شده شامل سه‌هزار چکیده از واکی‌پدیای فارسی که شامل بوده‌زار واژه است با استفاده از پانزده برچسب مختلف ارائه می‌شود که گام مهمی در ارتقای پژوهش‌های آینده این حوزه بوداشته خواهد شد. نتایج حاصل از ارزیابی سامانه پیشنهادی نشان می‌دهد که می‌توان با استفاده از داده معرفی شده به دقت ۷۲/۰۹ در معیار F رسید.

واژگان کلیدی: تشخیص موجودیت‌های نامدار، پردازش زبان طبیعی، بازنمایی معنایی واژه‌گان، یادگیری عمیق

## Named Entity Recognition in Persian Text using Deep Learning

Saeede Momtazi<sup>\*</sup> & Farzaneh Torabi

Department of Computer Engineering and Information Technology, Amirkabir University of Technology, Tehran, Iran

### Abstract

Named entities recognition is a fundamental task in the field of natural language processing. It is also known as a subset of information extraction. The process of recognizing named entities aims at finding proper nouns in the text and classifying them into predetermined classes such as names of people, organizations, and places. In this paper, we propose a named entity recognizer which benefits from neural network-based approaches for both word representation and entity tagging.

In the word representation part of the proposed model, two different vector representations are used and compared: (1) the semantic representation of words based on their context using word2vec continues skip-gram model, and (2) the semantic representation of words based on their context as well as characters forming them using fasttext. While the former model captures the semantic concepts of words, the latter one considers the morphological similarity of words as well. For the entity identification, a deep Bidirectional Long Short Term Memory (BiLSTM) network is used. Using LSTM model helps to consider the history of

<sup>1</sup> Named Entity Recognition

<sup>3</sup> Information Extraction

<sup>2</sup> Natural Language Processing

<sup>4</sup> Deep Learning

\* Corresponding author

\*نویسنده عهده‌دار مکاتبات

text when predicting entities, while the BiLSTM model expands this idea by benefiting from the history from both sides of the context.

Moreover, inline of the present research, an annotated corpus containing 3000 abstracts (90000 tokens) from the Persian Wikipedia is provided. In contrast to the available datasets in the field, which includes up to 7 label types, the new dataset contains 15 different labels, namely person individual, person group, organizations, locations, religions, books, magazines, movies, languages, nationalities, events, jobs, dates, fields, and other. Developing this dataset will be an important step in promoting future research in this field, especially for the tasks such as question answering that need wider range of entity types. The results of the proposed system show that by using the introduced model and the provided data, the system can achieve 72.92 F-measure.

**Keywords:** Name entity recognition, natural language processing, word embedding, deep learning

زبان طبیعی کاربرد دارد. اینکه سامانه چه نوع موجودیتی را تشخیص دهد و یا به بیان دیگر دسته‌های معنایی مورد نظرش چه باشند، وابسته به زمینه کاربردی سامانه است [2]. برای مثال شناسایی موجودیت‌های نامدار در علم زیست‌شناسی می‌تواند تشخیص اسمی وابسته به انواع پروتئین، دی‌ان‌ای، نوع سلول و غیره، در حوزه پژوهشی تشخیص انواع بیماری، دارو، و مرکز درمانی، در حوزه تجارت نام شرکتها و مؤسسات، تراکنش‌های مالی، بورس و غیره باشد؛ یا به صورت خیلی خاص‌منظره به عنوان مثال تنها برای تشخیص اسمی شرکتهای تولیدکننده فولاد به کار رود.

یکی از کاربردهای تشخیص موجودیت‌های نامدار در ترجمه مائشیتی رفع ابهام از ترجمه و افزایش دقت آن است. به عنوان مثال، اگر در متنی واژه Apple به عنوان موجودیت نامدار شناخته شده باشد و دارای برچسب باشد، در این صورت در هنگام ترجمه به عنوان شرکت اپل شناخته می‌شود و معنای سیب نخواهد داشت. در مثالی دیگر، در ترجمه فارسی به انگلیسی می‌توان به واژه زیبا اشاره کرد. اگر اسم فرد وجودیت نامدار باشد، نیاز به ترجمه ندارد، و در غیراین‌صورت باید به واژه beautiful ترجمه شود [13].

به طور کلی از دو روش قاعده‌مند و آماری برای تشخیص موجودیت‌های نامدار استفاده می‌شود [4]. در روش‌های قاعده‌مند، قوانینی تعریف می‌شود که براساس آنها موجودیت‌های نامدار تشخیص داده می‌شود. در روش آماری، از روش‌های یادگیری ماشین برای دسته‌بندی موجودیت‌های نامدار به هر مقوله استفاده می‌شود. استفاده از روش‌های دسته‌بندی با نظارت<sup>۱۱</sup> در این قسمت سبب می‌شود که با استفاده از پیکره‌ای که برچسب‌های موجودیت‌های نامدار دارد، بتوان مدلی را آموزش داد، و با آن مدل متن بدون برچسب را برچسب‌گذاری کرد. در مقاله حاضر، برای ساخت

<sup>۱۱</sup> Supervised

## ۱- مقدمه

شناسایی موجودیت‌های نامدار در پردازش زبان طبیعی به عملیاتی گفته می‌شود که در آن کلیه اسامی خاص موجود در متن شناسایی و استخراج می‌شوند و به مقولات از پیش تعریف شده‌ای مانند اسم افراد، سازمان‌ها، مکان‌ها و... دسته‌بندی می‌شوند. به این صورت که متن را بر اساس واژگان قطعه‌بندی و عبارات حاوی موجودیت نامدار را با برچسب‌زنی مشخص می‌کنیم.

این مفهوم برای نخستین بار در ششمین کنفرانس Message Understanding در سال ۱۹۹۵ مطرح شد. در واقع مسئله تشخیص موجودیت‌های نامدار در متن، به طور عمومی به دو زیر مسئله تشخیص و دسته‌بندی موجودیت‌ها تقسیم می‌شود. اسامی خاصی که تشخیص داده می‌شوند و همچنین قالبی که برای دسته‌بندی آنها به کار می‌رود، وابسته به نوع کاربرد آن خواهد بود. در سامانه‌های تشخیص موجودیت‌های نامدار، بیشتر بر روی تشخیص اسامی اشخاص، مکان‌ها و سازمان‌هایی که در یک متن آورده شده است تمرکز می‌شود [1].

نیاز به شناسایی موجودیت‌های نامدار در دنیای امروز که عصر ارتباطات و اطلاعات است، به شدت احساس می‌شود. شناسایی موجودیت‌های نامدار برای جستجوهای معنادار<sup>۱</sup>، ترجمه خودکار<sup>۲</sup>، استخراج اطلاعات از متن، کشف ارجاعات در متن<sup>۳</sup>، سامانه‌های پرسش و پاسخ<sup>۴</sup>، سامانه‌های خبره<sup>۵</sup>، کشف دانش<sup>۶</sup>، مدیریت دانش<sup>۷</sup>، نظرکاوی<sup>۸</sup>، بازیابی اطلاعات<sup>۹</sup>، تحلیل خبر<sup>۱۰</sup> و پسیاری دیگر از شاخه‌های مرتبط با پردازش

<sup>۱</sup> Semantic Search

<sup>۲</sup> Automatic Translation

<sup>۳</sup> Co-reference Resolution

<sup>۴</sup> Question Answering Systems

<sup>۵</sup> Expert Systems

<sup>۶</sup> Knowledge Discovery

<sup>۷</sup> Knowledge Management

<sup>۸</sup> Sentiment Analysis

<sup>۹</sup> Information Retrieval

<sup>۱۰</sup> News Analysis



فرانسوی، ایتالیایی، هلندی، چینی، روسی، کره‌ای، رومانیایی و ترکی نیز انجام شده است. بیشتر کارهای انجام‌شده متعلق به زبان، دامنه و یا گونه نوشتاری خاص است و بزرگ‌ترین مشکل این‌گونه سامانه‌ها نیز مربوط به انتقال‌شان به دامنه جدید است [5].

دو رویکرد اصلی که برای تشخیص موجودیت‌های نامدار استفاده می‌شوند، عبارتند از روش‌های قاعده‌مند و روش‌های آماری. در روش‌های قاعده‌مند، قوانینی تعریف می‌شود که از روی این قوانین می‌توانیم موجودیت‌های نامدار را تشخیص دهیم [6]. به عنوان مثال هرگاه عبارت "در سال...." در متن باشد، این عبارت می‌تواند آغاز یک موجودیت نامدار از نوع تاریخ باشد. به بیان دیگر با ظاهرشدن عبارت "در سال ۹۵۰ هجری قمری" در متن دنباله واژگان "سال ۹۵۰ هجری قمری" در این متن به عنوان موجودیت تاریخ تشخیص داده می‌شود. همچنین می‌توان در این رویکرد فهرستی تهیه کرد که شامل نوع خاصی از موجودیت‌های نامدار باشد. برای مثال فهرستی شامل تمام شهرهای جهان. اگر در یک متن، یکی از شهرهای موجود در این فهرست قرار داشت، آن شهر به عنوان موجودیت نامدار مکان در نظر گرفته شود.

ایده استفاده از این روش از وجود گنجوازه<sup>۲</sup> در علم جغرافیا الهام گرفته شده است. گنجوازه یک واژه‌نمای جغرافیایی است که در رابطه با یک نقشه یا یک اطلس استفاده می‌شود. آنها به طور معمول شامل اطلاعات مربوط به آرایش جغرافیایی، آمار اجتماعی و ویژگی‌های فیزیکی کشور، منطقه یا قاره هستند. محتوای گنجوازه می‌تواند شامل یک موقعیت هدف، ابعاد یک قله یا راه آبی، میزان جمعیت و میزان سواد باشد. این اطلاعات به طور کلی به موضوعات با نوشتۀ‌های یادشده و به ترتیب حروف الفبا مرتب می‌شوند.

ایده اصلی استفاده از گنجوازه در بحث جغرافیا و به منظور جمع‌آوری اطلاعات جغرافیایی مکان‌های مختلف بوده است که جغرافیدان‌ها از آن استفاده می‌کردند و بعد از این فرهنگ‌های جغرافیایی در زمینه‌های مربوط به پردازش زبان طبیعی و متن کاوی استفاده شد. هم‌اکنون اصطلاحات Lexicon، Gazatteer و Dictionary اغلب با اصطلاح فهرست جایگزین می‌شوند. گنجوازه به طور عمومی به فهرست بزرگی از نام مکان‌ها گفته می‌شود؛ اما این اصطلاح در زمینه تشخیص موجودیت‌های نامدار عمومی شده است و

سامانه تشخیص موجودیت‌های نامدار از روش‌های یادگیری ماشین باظارت و مبنی بر یادگیری عمیق استفاده می‌شود. یادگیری عمیق یک زیرشاخه بر مبنای مجموعه‌ای از الگوریتم‌ها است که در تلاش است، مفاهیم انتزاعی سطح بالا در دادگان را مدل کنند. این فرایند را با استفاده از یک شبکه عمیق که دارای چندین لایه پردازشی مشکل از چندین لایه تبدیلات خطی و غیرخطی است، مدل می‌کنند؛ به بیان دیگر، پایه آن بر یادگیری نمایش دانش و ویژگی‌ها در لایه‌های مدل است که در آن داده‌های بدون برچسب به سامانه داده می‌شود و سامانه با استخراج واژه‌های آن برای هر واژه بردار ویژگی آن را بر اساس ویژگی‌های مفهومی از متن استخراج می‌کند. این عملیات را می‌توان در دو مرحله انجام داد. ابتدا برای هر واژه بردار مربوطه استخراج می‌شود و سپس با استفاده از الگوریتم شبکه عصبی<sup>۱</sup> به کمک بردارهای به دست آمده و داده‌های آموزش (پیکره برچسب‌خورده) داده‌های آزمون برچسب‌دهی می‌شوند.

برای این منظور، در مقاله حاضر، دو مدل مختلف بازنمایی برای یادگیری عمیق شبکه استفاده و هر واژه با دو نوع بردار بازنمایی جایگزین می‌شود. بدین ترتیب، به ازای هر واژه یک بردار بازنمایی واژه و یک بردار بازنمایی ویژگی حروف آن واژه را خواهیم داشت. با کمک این بردارها و داده‌های آموزش می‌توان به تشخیص موجودیت‌های نامدار پرداخت.

ساختمار مقاله حاضر بدین شرح است: در بخش ۲، مروری بر روش‌های تشخیص موجودیت‌های نامدار استفاده شده خواهیم داشت؛ در بخش ۳، درخصوص شبکه عصبی و نحوه به کار گیری آن در این مقاله بحث خواهد شد. در بخش ۴، مدل پیشنهادی توصیف و در بخش ۵، توضیحاتی از دادگان تهیه شده ارائه می‌شود. در بخش ۶، به بررسی آزمایش‌های مربوطه می‌پردازیم، و در نهایت نتیجه‌گیری کلی در بخش ۷ ارائه می‌شود.

## ۲- کارهای انجام‌شده

در زبان‌های مختلف بر روی مبحث "تشخیص و دسته‌بندی موجودیت‌های نامدار" به عنوان زیرشاخه‌ای از پردازش زبان طبیعی پژوهش‌های متعددی انجام شده است. اگرچه نسبت بالایی از پژوهش‌ها متعلق به زبان انگلیسی است، فعالیت‌هایی برای زبان‌هایی چون آلمانی، یونانی، زبانی،

<sup>1</sup> Neural Network

ساخت یک مدل آماری نیاز دارد. برخلاف رهیافت‌های مبتنی بر قاعده، روش‌های یادگیری ماشین مستقل از حوزه و زبان عمل می‌کنند [7].

در پژوهش انجام شده توسط موروال<sup>۵</sup> و همکاران مدل مخفی مارکوف برای تشخیص موجودیت‌های نامدار مورد استفاده قرار گرفته است [۸]. در پژوهشی دیگر که توسط لی<sup>۶</sup> و همکاران انجام گرفته روش میدان تصادفی شرطی برای تشخیص موجودیت‌های نامدار دانریز به کار گرفته شده است [۹]. این روش همچنین برای اندازه زبان‌ها نیز مورد استفاده قرار گرفته است؛ که از جمله آن می‌توان به زبان‌های ترکی، عربی، بنگالی و هندی اشاره کرد [۱۰, ۱۱, ۱۲]. الگوریتم آنتروپی بیشینه نیز در این حوزه توسط کوران و کلارک<sup>۷</sup> مورد استفاده قرار گرفته و توانسته است در یک چارچوب مستقل از زبان برای تشخیص موجودیت‌های نامدار در زبان‌های مختلف مورد استفاده قرار گیرد [۱۳].

علاوه‌بر الگوریتم‌های یادشده، برای تشخیص موجودیت‌های نامدار، از شبکه‌های عصبی مختلفی نیز استفاده شده است که روند تشخیص را بهبود می‌دهد و وقت کار را بالا می‌برد. شبکه‌های عصبی معروفی که در این زمینه به کار می‌روند، شبکه عصبی بازگشتی<sup>۸</sup> و شبکه عصبی حافظه طولانی کوتاه مدت<sup>۹</sup> است. از جمله پژوهش‌های این حوزه می‌توان به پژوهش لی<sup>۱۰</sup> و همکاران اشاره کرد که از شبکه عصبی بازگشتی برای تشخیص موجودیت‌های نامدار در حوزه پزشکی استفاده کرده‌اند [۱۴]. گفتنی است، استخراج موجودیت‌های نامدار از متون پزشکی تنها به روش‌های مبتنی بر شبکه عصبی خلاصه نمی‌شود و کارهای انجام شده در این حوزه با استفاده از روش‌های مدل مخفی مارکوف، آنتروپی بیشینه و میدان تصادفی شرطی نیز صورت گرفته است [۱۵, ۱۶].

شبکه‌های عصبی یادشده به تفضیل در بخش ۳ توضیح داده خواهد شد.

## ۱-۲- کارهای انجام شده برای زبان فارسی

نخستین کارهای انجام شده برای تشخیص موجودیت‌های نامدار فارسی بر مبنای روش‌های مبتنی بر قاعده صورت گرفته است.

<sup>۵</sup> Morwal

<sup>۶</sup> Lee

<sup>۷</sup> Curran و Clark

<sup>۸</sup> Recurrent Neural Network (RNN)

<sup>۹</sup> Long Short Term Memory (LSTM)

<sup>۱۰</sup> Li

حتی از نام گنجوازه برای فهرست واژگان دیگر هم استفاده می‌شود.

این رویکرد در بسیاری از موارد به درستی عمل می‌کند؛ ولی در دو صورت با ابهام مواجه می‌شود: ۱) زمانی که واژه موجود در واژه‌نامه به صورت کامل استفاده نشده باشد؛ به عنوان مثال، اگر در واژه‌نامه واژه "وزارت علوم، تحقیقات و فناوری" موجود باشد، این روش در تشخیص یک موجودیت که در آن تنها واژه "وزارت علوم" آورده شده است، ضعیف عمل می‌کند. مورد دیگر ابهام زمانی خواهد بود که یک واژه، معانی متفاوتی داشته باشد و در واژه‌نامه به اشتباه به معنی دیگری مرتبط شود. برای مثال، ممکن است واژه "هما" در یک متن به عنوان اسم شخص استفاده شده باشد، اما به اشتباه به عنوان مخفف "هوایمایی ملی ایران" تشخیص داده شود.

در رویکرد دوم که در سامانه‌های مبتنی بر یادگیری ماشینی مورد استفاده قرار می‌گیرد، هدف از رهیافت تشخیص واحدهای اسمی موجودیت‌های نامدار تبدیل مسئله تشخیص به مسئله دسته‌بندی است و از یک مدل آماری دسته‌بندی برای حل آن استفاده می‌شود. در این روش، مدل به دنبال تشخیص الگوها و یافتن رابطه آنها با متن و ساختن یک مدل آماری و الگوریتم یادگیری ماشین است. این سامانه‌ها اسمی خاص را یافته و آنها را براساس مدل به دست آمده با استفاده از روش‌های یادگیری ماشین به مقوله‌های از پیش تعیین شده مانند اشخاص، مکان‌ها، زمان‌ها، مذاهب، سازمان‌ها و ... تقسیم می‌کند.

روش‌های مبتنی بر یادگیری که به صورت بانتظارت عمل می‌کنند، نیاز به حجم زیادی از متون برچسب‌گذاری شده دارند؛ و با در اختیار داشتن این داده‌ها، به استفاده از الگوریتم‌هایی نظری درخت تصمیم‌گیری<sup>۱</sup> و مدل مخفی مارکوف<sup>۲</sup>، آنتروپی بیشینه<sup>۳</sup>، میدان تصادفی شرطی<sup>۴</sup> و غیره می‌پردازند. در روش‌های یادگیری بانتظارت ابتدا سامانه توسعه پیکره‌ای به عنوان داده آموزش که به صورت دستی و به وسیله انسان برچسب‌گذاری شده است، آموزش می‌بیند و با یادگیری از طریق این داده‌ها، به تشخیص خودکار اسامی خاص در متون دیده نشده می‌پردازد. گفتنی است، که روش‌های بانتظارت به داده‌های برچسب‌گذاری شده برای

<sup>۱</sup> Decision Tree

<sup>۲</sup> Hidden Markov Model

<sup>۳</sup> Maximum Entropy

<sup>۴</sup> Conditional Random Field



دشتی پور و همکاران نیز از ترکیبی ازو روش‌های مبتنی بر قاعده که از فرهنگ لغت و قواعد زبان‌شناسی بهره برده است و همچنین الگوریتم ماشین بردار پشتیبان استفاده کردند. در این پژوهش برچسب‌های شخص، مکان و تاریخ مد نظر قرار گرفته است [23].

شاکری و همکاران نیز ترکیبی ازو روش‌های مبتنی بر فرهنگ لغت، بردار تصادفی شرطی و شبکه عصبی را به کار برده‌اند. همچنین اطلاعات زبان‌شناختی از جمله برچسب مقوله نحوی، ریشه واژگان و برچسب عبارات حاصل از تجزیه سطحی زبان، مورد استفاده قرار گرفته است [24]. اگرچه استفاده از اطلاعات زبان‌شناختی می‌تواند نقش مثبتی در تشخیص موجودیت‌های نامدار داشته باشد؛ اما این اطلاعات باعث وابستگی کامل سامانه به زبان می‌شود. «پیکره موجودیت‌های نامدار پیما» محصول این پژوهش است. برچسب‌های درنظر گرفته شده در این پیکره نیز همانند پیکره آرمان محدود به شش مورد است و قابلیت استخراج بسیاری از اطلاعات مرتبط با موجودیت‌های نامدار را ندارد.

### ۳- شبکه‌های عصبی

به طور کلی از شبکه‌های عصبی در تشخیص موجودیت‌های نامدار در دو بخش اصلی استفاده می‌شود: ۱) در بازنمایی کلیه واژگان متن، ۲) در تعیین برچسب واژگان. در این مقاله، برای هر دو مرحله یادشده از شبکه‌های عصبی استفاده می‌شود.

#### ۱-۳- شبکه‌های عصبی برای بازنمایی واژگان

برای بسیاری از روش‌های پردازش متن، نیاز به نمایش عددی واژگان و متون است تا بتوان از انواع روش‌های عددی حوزه یادگیری ماشین مانند پیش‌تر الگوریتم‌های دسته‌بندی روی واژه‌ها و استناد استفاده کرد. یکی از رهیافت‌هایی که در این حوزه بسیار رایج شده، نمایش برداری واژگان و جملات است.

فرض کنید، فرهنگ لغتی با  $N$  واژه داریم که به ترتیب الفبا مرتب شده‌اند و هر واژه یک مکان مشخص در این فرهنگ لغت دارد؛ حال برای نمایش هر واژه، برداری را در نظر می‌گیریم با طول  $N$  که هر خانه آن، متناظر با یک لغت در فرهنگ لغت است که برای راحتی کار فرض می‌کنیم، شماره آن خانه بردار، همان اندیس لغت مربوطه در این فرهنگ لغت خواهد بود؛ با این پیش‌فرض، برای هر لغت یک بردار به طول  $N$  داریم که همه خانه‌های آن به جز خانه متناظر با آن واژه صفر خواهد بود؛ در خود ستون متناظر با واژه بسامد آن ذخیره خواهد شد [25].

در روش ارائه شده توسط مرتضوی و شمس‌فرد بعد از انجام پیش‌پردازش‌های لازم از جمله نرمال‌سازی و همچنین برچسب‌زنی مقوله‌های نحوی، با تعریف قوانین دستی به تشخیص موجودیت‌های نامدار پرداختند [17].

کلالی و بذرافکن از یک رویکرد مبتنی بر فرهنگ لغت برای تشخیص موجودیت‌های نامدار استفاده کرده‌اند [18]. در این پژوهش از برچسب‌های مقوله نحوی پیکره بی‌جن‌خان بهره برده شده است [19]. همچنین مقلالات ویکی‌پدیا برای ساخت فرهنگ لغت مورد استفاده قرار گرفته است.

مرادیان نسب و ممتازی از قواعد تعریف شده و همچنین فرهنگ لغت برای تشخیص موجودیت‌های نامدار استفاده کرده‌اند [6].

در پژوهشی دیگر عبدالوس و مینایی بیدگلی نشان داده‌اند که با درنظر گرفتن ویژگی کسره اضافه در واژگان در چهارچوب یک ساختار قاعده‌محور می‌توان باعث بهبود تشخیص موجودیت‌های نامدار شد [20].

معیار  $F$ ٪ ۷۴٪ ۸۳٪ ۸۹٪ ۸۲٪ به ترتیب توسط مقلالات بالا گزارش شده است، اما به دلیل یکسان بودن دادگان آزمون، این نتایج قابل مقایسه نیستند. گفتندی است در تمامی موارد ذکر شده تعداد برچسب‌های مورد استفاده بسیار محدود بوده و در بیشتر موارد این برچسب‌ها به سه موجودیت شخص، سازمان و مکان خلاصه شده است.

پس از روش‌های مبتنی بر قاعده، روش‌های ترکیبی که از هر دو مدل مبتنی بر قاعده و مبتنی بر یادگیری ماشین استفاده می‌کنند، روی کار آمد.

احمدی و مرادی برای تشخیص موجودیت‌های نامدار از یک رویکرد ترکیبی بهره برده‌اند که در آن علاوه بر روش مبتنی بر قاعده، روش یادگیری ماشین با استفاده از الگوریتم مدل مخفی مارکوف مورد استفاده قرار گرفته است [21].

پوستچی و همکاران از روش‌های مختلف یادگیری ماشین از جمله بردار تصادفی شرطی، ماشین بردار پشتیبان و مدل مخفی مارکوف برای این هدف استفاده کرده‌اند و بهترین دقت را با استفاده از مدل ترکیبی ماشین بردار پشتیبان و مدل مخفی مارکوف به دست آورده‌اند. در این پژوهش همچنین یک پیکره تحت عنوان «پیکره واحدهای اسمی آرمان» ارائه شده که شامل برچسب‌های شخص، سازمان، مکان، امکانات، محصولات و رویدادها است. با توجه به این که برچسب «محصولات» بسیار کلی است، هیچ‌گونه تفکیکی بین موارد مانند اسم کتاب، اسم مجله و یا اسم فیلم وجود ندارد؛ ضمن این‌که اطلاعاتی مانند شغل، زبان، ملیت، مذهب در این پیکره پوشش داده نشده است [22].

در ساختار این شبکه هیچ تابع فعال‌سازی غیرخطی در نورون‌های پنهان وجود ندارد؛ اما نورون‌های خروجی از تابع سافت مکس<sup>۳</sup> استفاده می‌کنند. این شبکه بر روی دو واژه آموزش داده می‌شود، بهنحوی که ورودی یک بردار یک-روشن<sup>۴</sup> نشان‌گر واژه ورودی و خروجی آموزش نیز یک بردار یک-روشن نشان‌گر واژه خروجی است؛ اما هنگامی که شبکه آموزش‌دهد روى یک واژه ورودی ارزیابی می‌شود، بردار خروجی درواقع یک توزع احتمالاتی است.

همچنین با ایجاد تغییراتی در الگوریتم بردارهای بازنمایی واژگان می‌توان از ویژگی‌های حروف واژگان نیز بهره گرفت و برای هر واژه برداری از ویژگی‌های حروف آن را استخراج کرد که به آن تعابیه واژگان در سطح نویسه<sup>۵</sup> گفته می‌شود [28].

در این راستا، از الگوریتم CharWNN استفاده می‌شود که معماری شبکه عصبی را برای طبقه‌بندی تکراری گسترش می‌دهد و با اضافه کردن یک لایه پیچش<sup>۶</sup> برای استخراج نمایه‌های سطوح حروف مورد استفاده قرار می‌گیرد. با توجه به جمله داده شده، شبکه به ازای هر واژه امتیازی برای هر واژه در بافت آن واژه در نظر می‌گیرد و بنا بر امتیازات یک واژه، شبکه به عنوان ورودی یک پنجه با اندازه ثابتی از واژگان متتمرکز در واژه هدف را می‌گیرد. ورودی از طریق دنباله‌ای از لایه‌ها که ویژگی‌هایی با افزایش سطوح پیچیده دارند، انتقال می‌یابد؛ سپس خروجی برای همه جملات با استفاده از الگوریتم ویتری برداری پردازش می‌شود [28].

**۲-۳-۲- شبکه‌های عصبی برای برچسب‌زنی متن**  
همان‌طور که گفته شد، برای برچسب‌زنی موجودیت نامدار در بین شبکه‌های عصبی، شبکه عصبی بازگشتی و به‌طور خاص شبکه عصبی حافظه طولانی کوتاه‌مدت دو طرفه<sup>۷</sup> بیشتر مورد استفاده قرار می‌گیرد که در این قسمت به توضیح آنها پرداخته می‌شود.

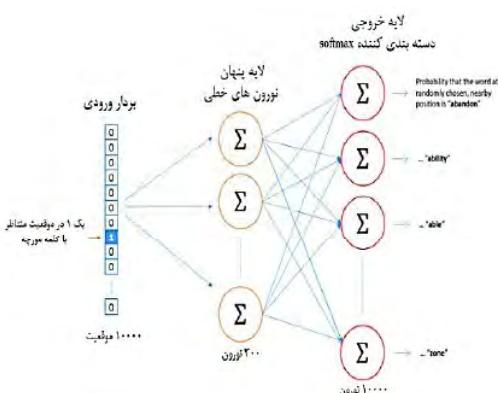
نحوه تفکر انسان‌ها در هر لحظه به گونه‌ای است که از اطلاعات گذشته خود بهره می‌برند. به عنوان مثال، هنگام مطالعه یک مطلب، معنی هر واژه را می‌توان با توجه به دانشی که از خواندن واژه‌های قبلی کسب شده درک کرد.

اگرچه روش بالا کاربرد زیادی در پردازش زبان طبیعی داشته اما دارای نواقص زیادی است. یکی از نواقص اصلی این روش بازنمایی عدم درنظر گرفتن ارتباط میان واژگان است. برای رفع این مشکل استفاده از روش‌های مبتنی بر شبکه عصبی پیشنهاد شده است.

برای ایجاد بردارهای بازنمایی واژگان بر مبنای شبکه عصبی از الگوریتم word2vec استفاده شده است که این الگوریتم توسط تیمی از پژوهش‌گران به رهبری توماس میکولوف<sup>۸</sup> در گوگل ایجاد شد [26]. این الگوریتم سپس توسط سایر پژوهش‌گران مورد تجزیه و تحلیل قرار گرفت. استفاده از الگوریتم word2vec دارای مزایای بسیاری در مقایسه با الگوریتم‌های قبلی مانند تجزیه و تحلیل معنایی نهان است.

word2vec گروهی از مدل‌های مرتبه است که برای تولید بازنمایی واژگان استفاده می‌شود<sup>۹</sup>. این مدل‌ها مبتنی بر شبکه‌های عصبی دارای دو لایه کم‌عمق هستند که برای بازنمایی محتوای واژگان زبان آموزش داده می‌شوند. در تبدیل واژه به بردار به عنوان ورودی، یک متن با حجم بالا در نظر گرفته می‌شود و یک فضای برداری را که به‌طور معمول از چندصد قطعه تشکیل شده تولید می‌کند. با هر واژه منحصر به فرد در قسمت پیکره، یک بردار در فضای بردار قرار می‌گیرد؛ به طوری که واژه‌هایی که دارای محتوای مشترکی در پیکره هستند، بردار آنها در فضای نزدیکی یکدیگر قرار می‌گیرند [26].

در شکل (۱) معماری شبکه عصبی مورد استفاده در این روش نمایش داده شده است [27].



(شکل-۱): نمونه‌ای از معماری شبکه عصبی بازنمایی واژگان  
(Figure-1): Neural network architecture for word representation

<sup>۱</sup> Tomas Mikolov

<sup>۳</sup> مدل‌هایی مانند پرس نکاشت و کیمیه واژگان پیوسته، همچنین نسخه کسترنش داده شده از آنها از جمله این مدل‌ها هستند.

<sup>۴</sup> Soft-max

<sup>۵</sup> One-hot

<sup>۶</sup> character level word embedding

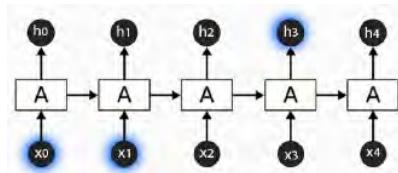
<sup>۷</sup> Convolution

<sup>۸</sup> Bidirectional LSTM

عصبی بازگشتی نخستین انتخاب برای کار با چنین داده‌هایی است.

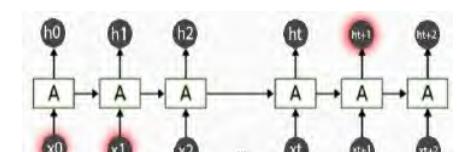
این شبکه‌ها در سال‌های اخیر مکرراً مورد استفاده قرار گرفته‌اند که منجر به موفقیت‌های بسیار چشم‌گیری در حوزه‌های مختلف از جمله تشخیص صدا، مدل کردن زبان، ترجمه، درج خودکار توضیح برای تصویر و... شده است [29]. اگرچه به نظر می‌رسد در بسیاری مواقع برای به دست آوردن اطلاعات مورد نیاز، تنها مراجعه به اطلاعات گذشته نزدیک کافی است، در برخی موارد اطلاعات بیشتری مورد نیاز است. به عنوان مثال، با درنظر گفتن جمله "من زبان فرانسه را خیلی راحت صحبت می‌کنم... من متولد کشور فرانسه هستم." با توجه به اطلاعات اخیر (یعنی چهار پنج واژه قبل از واژه فرانسه)، می‌توان گفت که این واژه به احتمال اسم یک کشور است، ولی اگر مدل بخواهد به طور دقیق نام کشور را تشخیص دهد، نیازمند اطلاعات دورتر (یعنی تا ده یا بیست واژه قبل از آخرین واژه) است. به بیان دیگر، ممکن است، فاصله بین اطلاعات مرتبط و قسمتی که به این اطلاعات نیاز داریم، زیاد باشد.

متاسفانه، هر چه این فاصله افزایش پیدا می‌کند، شبکه‌های عصبی بازگشتی قدرت‌شان را در به‌یادآوردن و استفاده از اطلاعاتی که در گذشته دورتر یاد گرفته‌اند، از دست می‌دهند و به عبارتی توانایی استفاده از اطلاعات گذشته دورتر را ندارند. شکل‌های (۴) و (۵) به نمایش این مشکل پرداخته‌اند. برای حل این مشکل شبکه‌های عصبی حافظه طولانی کوتاه‌مدت پیشنهاد شده‌اند [30].



(شکل-۴): امکان استفاده شبکه عصبی بازگشتی از اطلاعات گذشته نزدیک

(Figure-4): The possibility of using short past information in a recursive neural network



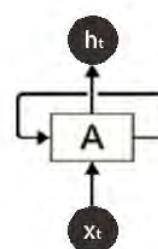
(شکل-۵): مشکل شبکه عصبی بازگشتی در به‌یادآوردن اطلاعات گذشته دور

(Figure-5): The problem of recurring neural network in recalling long past information

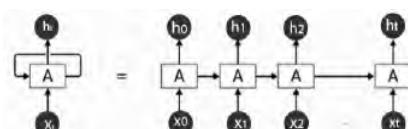
به عبارتی دیگر، هنگام مطالعه یک متن، درک و فهمی که در مورد آن متن با توجه به خواندن واژگان قبل کسب شده است از بین نمی‌رود؛ بلکه به صورت پیوسته با خواندن هر واژه جدید، نسبت به آن متنی که خوانده می‌شود، درک بیشتری کسب می‌شود.

شبکه‌های عصبی متداوی که مختصمان یادگیری ماشین از آنها استفاده می‌کردند، نمی‌توانستند به این شیوه شبیه انسان عمل کنند و این یک نقص بزرگ برای این شبکه‌ها محسوب می‌شد [29].

برای برطرف کردن این مشکل شبکه‌های عصبی بازگشتی طراحی شدند. این شبکه‌ها در داخل خود دارای یک حلقه بازگشتی هستند که منجر می‌شود اطلاعاتی که از لحظات قبلی به دست آمده از بین نزود و در شبکه باقی بماند. در شکل (۲)، بخش A، مقدار  $x_t$  به عنوان ورودی دریافت و مقدار  $h_t$  را به خروجی می‌برد. حلقه، باعث می‌شود که اطلاعات از یک مرحله به مرحله بعد ارسال شود. در واقع شبکه‌های عصبی بازگشتی را می‌توان به صورت چندین رونوشت یکسان از یک شبکه عصبی در نظر گرفت که هر کدام اطلاعاتش را به شبکه بعدی منتقل می‌کند. در شکل (۳)، وضعیت شبکه عصبی بازگشتی در صورت بازگردان حلقه نمایش داده شده است.



(شکل-۲): شبکه‌های عصبی بازگشتی دارای حلقه  
(Figure-2): Recursive neural networks with a ring



(شکل-۳): شبکه عصبی بازگشتی باز شده  
(Figure-3): Expanded recursive neural network

با توجه به زنجیره‌واربودن شبکه‌های عصبی بازگشتی، می‌توان تشخیص داد که این شبکه‌ها در حد زیادی به دنباله‌ها و فهرست‌ها مرتبط هستند. در حقیقت شبکه‌های

شکل‌های (۲-۳) از آدرس زیر مورد استفاده قرار گرفته‌اند: ۱  
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

دارند که باعث بهبود عملکردشان شده است. در این مقاله نیز با توجه به ویژگی یادشده از این نوع شبکه‌های عصبی بازگشتی استفاده می‌شود.

#### ۴- مدل پیشنهادی

به طور کلی "سامانه تشخیص موجودیت‌های نامدار زبان فارسی" در بخش‌های زیر قابل بررسی و پیاده‌سازی است: در این سامانه یک متن به عنوان ورودی ارائه می‌شود و اسامی به تفکیک طبقه مربوط به آن به عنوان خروجی سامانه بدست می‌آید. مراحل لازم تشخیص موجودیت‌های نامدار یک متن عبارتند از:

- ۱- متن ورودی به سامانه ارائه می‌شود، مانند جمله: "محمد جمعه به دانشگاه نرفت."

۲- با استفاده از یک نشان‌گذار، واژگان در متن ورودی از یکدیگر جدا می‌شوند. (محمد/جمعه/به/دانشگاه/نرفت)

۳- با استفاده از روش یادگیری بدون نظارت<sup>۳</sup> مبتنی بر شبکه‌های عصبی، برای هر یک از واژگان بردار ویژگی مورد نیاز بر مبنای واژه و همچنین حروف تشکیل‌دهنده واژه استخراج می‌شود.

۴- با استفاده از روش یادگیری با نظارت مبتنی بر شبکه‌های عمیق و دادگان آموزش، برچسب‌دهی دادگان آزمون انجام می‌شود.

۵- معیار ارزیابی دقت<sup>۴</sup>، صحت<sup>۵</sup>، فراخوانی<sup>۶</sup> و معیار F<sup>۷</sup> بر روی خروجی سیستم محاسبه می‌شود.

همان‌طور که گفته شد، برای انجام این پروژه از الگوریتم شبکه عصبی حافظه طولانی کوتاه‌مدت دو طرفه استفاده شده که برگرفته از شبکه‌های عصبی بازگشتی است و می‌تواند اطلاعات گذشته دورتری از بردارها را در حافظه خود نگه دارد. همچنین با بهره‌گیری از الگوریتم word2vec دو بردار تعبیه واژگان در سطح واژه و در سطح نویسه ایجاد شده‌اند که بردار بازنمایی واژگان و بردارهای بازنمایی بر مبنای حروف متشكل هر واژه هستند. در این مقاله، میزان دقت و کارایی روش با استفاده از این دو بردار نیز مورد بررسی و مقایسه قرار می‌گیرد. در شکل (۸) ساختار کلی تشخیص موجودیت‌های نامدار در پژوهش حاضر نمایش داده شده است.

<sup>3</sup> Unsupervised

<sup>4</sup> Accuracy

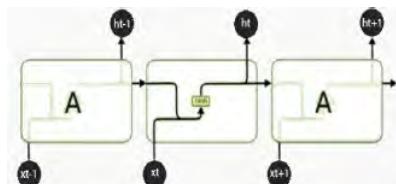
<sup>5</sup> Precision

<sup>6</sup> Recall

<sup>7</sup> F-Measure

شبکه‌های حافظه طولانی کوتاه‌مدت نوع خاصی از شبکه‌های عصبی بازگشتی هستند که توانایی یادگیری و بستگی‌های بلندمدت را دارند. این شبکه‌ها برای نخستین بار توسط هاچریت<sup>۸</sup> و اسمیدهابر<sup>۹</sup> در سال ۱۹۹۷ معرفی شدند [۳۱]. البته تعداد زیادی از پژوهش‌گران در بهبود این شبکه‌ها نقش داشتند.

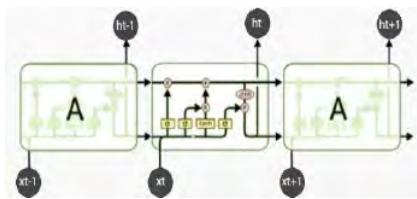
هدف از طراحی شبکه‌های حافظه طولانی کوتاه‌مدت، حل کردن مشکل وایستگی بلندمدت بود. به عبارت دیگر، به یادسپاری اطلاعات برای بازه‌های زمانی بلندمدت، رفتار پیش‌فرض و عادی شبکه‌های حافظه طولانی کوتاه‌مدت است؛ و ساختار آنها به صورتی است که اطلاعات خیلی دور را به خوبی یاد می‌گیرند که این ویژگی در ساختار آنها نهفته است [۳۲].



(شکل-۶): مازول‌های تکرارشونده در شبکه‌های عصبی بازگشتی استاندارد فقط دارای یک لایه هستند.

(Figure-6): Routine modules in a standard recursive neural network only have one layer

شبکه‌های حافظه طولانی کوتاه‌مدت ساختار دنباله‌دار یا زنجیره‌مانندی دارند، ولی بخش تکرارشونده، ساختار متفاوتی دارد که به جای داشتن تنها یک لایه شبکه عصبی، چهار لایه دارند و طبق ساختار ویژه‌ای با یکدیگر در تعامل و ارتباط هستند. تفاوت ساختار داخلی دو شبکه در شکل‌های (۶) و (۷) نمایش داده شده است.



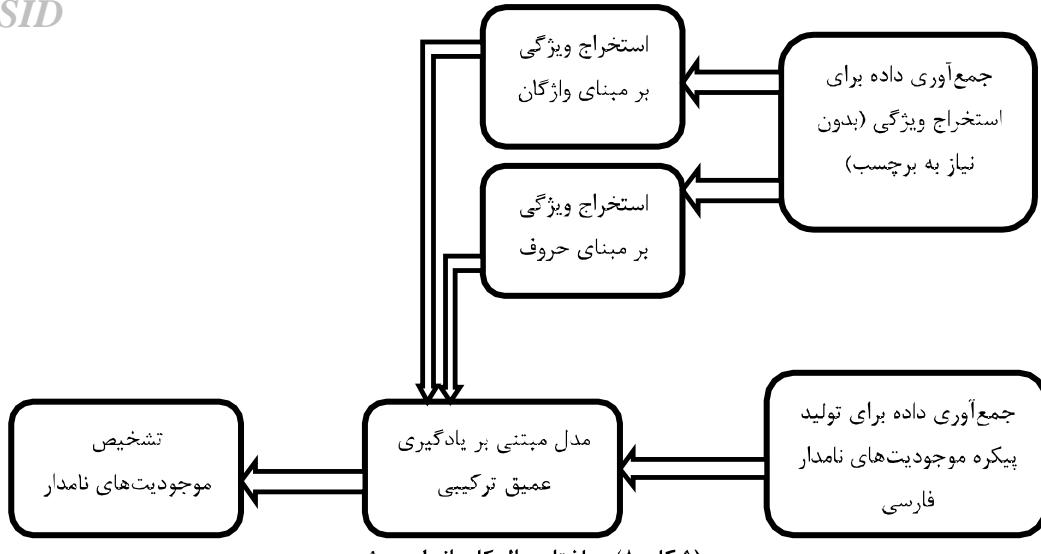
(شکل-۷): مازول‌های تکرارشونده در LSTM‌ها دارای ۴ لایه‌اند که با همدیگر در تعامل‌لند

(Figure-7): Repetitive modules in LSTMs have 4 layers that interact with each other

همچنین نوع توسعه‌یافته شبکه‌های حافظه طولانی کوتاه‌مدت شبکه‌های حافظه طولانی کوتاه‌مدت دو طرفه هستند که علاوه‌بر آن که وایستگی دورتری را در دنباله واژگان در نظر می‌گیرند، به اطلاعات هر دو جهت دسترسی

<sup>8</sup> Hochreiter

<sup>9</sup> Schmidhuber



(شکل-۸): ساختار روال کلی انجام پروژه  
(Figure-8): Overview of the overall project execution

بالاتری انجام داد؛ درنتیجه، در این مقاله توجه خاصی به کیفیت تحلیل داده شده و تا جای ممکن دادگان از بهترین و متنوع‌ترین داده‌های ممکن جمع‌آوری شده است. در ادامه این بخش، به صورت اجمالی در مورد نحوه برچسبزنی داده‌ها می‌پردازم.

### ۱-۵-نمایش مدل‌های IO و IOB

برای اختصاص برچسب به هر واژه، ابتدا متن را به واژگان سازنده آن تقطیع کرده و سپس به‌کمک دو روش می‌توان نوع موجودیت نامدار یافته‌شده را معین کرد. در روش نخست به‌ازای هر اسم خاص موجود میان واژگان متن، برچسب متناسب با نوع اسم خاص مربوطه را به آن اختصاص می‌دهیم و به‌ازای سایر واژگانی که اسم خاص تشخیص داده نشده‌اند برچسب O را که مخفف واژه Out است، تشخیص می‌دهیم. به این روش برچسب‌گذاری مدل IO گفته می‌شود. که در جدول (۱) نمونه‌ای از آن مشخص شده است.

در روش دوم، کار برچسب‌گذاری را با دقت بالاتری انجام می‌دهیم؛ بدین صورت که با علاوه‌ی ابتدا و انتهای هر واژه خاص را که ممکن است، دنباله‌دار باشد، معین می‌کنیم. برای این منظور، شروع هر واژه خاص را با اضافه کردن حرف b به ابتدای برچسب آن مشخص و برای نمایش دنباله واژه مورد نظر، برچسب ادامه آن را با افزودن حرف a به آن تعیین می‌کنیم که به این روش برچسب‌گذاری موجودیت‌های نامدار مدل IO می‌گوییم [35]. مثالی از این مدل در جدول (۲) آورده شده است.

## ۵-دادگان

برای یادگیری مدل، نیازمند پیکره‌ای برای آموزش شبکه عصبی هستیم. از جمله دادگان موجود در زمینه تشخیص موجودیت‌های نامدار در زبان فارسی دو پیکره موجودیت‌های نامدار آرمان رایان شریف و بانک درختی هسته‌بنیان فارسی هستند [33,34]. در این دو منبع تنها موجودیت‌های نامدار مربوط به نام اشخاص، موقعیت‌های مکانی و اسمی مربوط به سازمان‌ها برچسب خورده‌اند. در پیکره نخست اسامی رویدادها، امکانات و محصولات نیز مشخص شده است؛ این در حالی است که در بسیاری از کاربردهای تشخیص موجودیت‌های نامدار، مانند سامانه‌های پرسش و پاسخ و یا تحلیل اخبار و ...، نیازمند پوشش موجودیت‌های نامدار بیشتری مانند زبان‌ها، ملیت‌ها، رخدادها، مشاغل، کتاب‌ها، اسامی فیلم‌ها، تاریخ‌ها، مذهب، زمینه‌های علمی و دانش‌ها، روزنامه‌ها و سایر اسامی خاص در زبان هستند.

از آنجاکه در پیکره‌های یادشده این موارد پوشش داده نشده است، برای طراحی یک سامانه تشخیص موجودیت‌های نامدار جامع، در راستای پژوهش حاضر، پیکره‌ای از دادگان مربوط به ویکی‌پدیا جمع‌آوری شده و پانزده برچسب موجودیت‌های نامدار یادشده برای حدود سه‌هزار چکیده استخراج و برای این کار به صفحات متنوعی از ویکی‌پدیا مراجعه شده است.

جمع‌آوری داده یکی از اصلی‌ترین بخش‌ها در یک کار پژوهشی است. در صورت تهیه داده با کیفیت بالا، می‌توان تجزیه و تحلیل و نتیجه‌گیری از داده‌ها را با سرعت و دقت

|       |      |
|-------|------|
| b-REL | شیعه |
| O     | است  |
| O     | .    |

اگرچه روش IOB در برچسب‌گذاری موجودیت‌های نامدار دقیق‌تر است، پژوهش‌های انجام‌شده بر روی زبان‌هایی مانند انگلیسی، چک، اسپانیایی و هلندی [36] نشان داده است که تفاوت معناداری بین نتایج به دست آمده از این دو روش وجود ندارد؛ اما با توجه به ایراد مهمی که به مدل برچسب‌گذاری IO بدلیل عدم تشخیص مرز بین موجودیت‌های نامداری که پشت سر هم در متن ظاهر می‌شود، وارد است، روش IO برای زبان فارسی توصیه نمی‌شود. به عنوان نمونه در مثال جدول (۳) دو موجودیت نامدار محمد علی صادقی و فرهاد در مدل IO قابل تمایز نیستند. یک دلیل عمدی برای این اشکال این است که ساختار دستور زبان فارسی به صورت فاعل-مفعول- فعل است. درنتیجه میزان رخداد این گونه ابهامات در متن بسیار بالاتر از سایر زبان‌ها است؛ زیرا موجودیت‌های نامدار زیادی در قالب فعل و مفعول پشت سر هم در جمله ظاهر می‌شوند؛ در حالی که در سایر زبان‌ها مانند انگلیسی ساختار دستوری زبان به صورت فعل- فعل- مفعول است که درصد رخداد باهم‌آبی موجودیت‌ها را کاهش می‌دهد. این امر به لزوم استفاده از مدل IOB در زبان فارسی تأکید دارد. بنابراین برای رسیدن به دقت بالا در کار تشخیص موجودیت‌های نامدار، در مقاله حاضر، از روش برچسب‌گذاری IOB استفاده شده است.

(جدول-۳): مثالی از رفع ابهام برچسب‌گذاری به روش IOB  
(Table-3): An example of removing ambiguity with IOB labeling

| برچسب موجودیت<br>نامدار IO | وازگان | برچسب موجودیت<br>نامدار IOB | وازگان |
|----------------------------|--------|-----------------------------|--------|
| PER                        | محمد   | i-PER                       | محمد   |
| PER                        | علی    | i-PER                       | علی    |
| PER                        | صادقی  | i-PER                       | صادقی  |
| PER                        | فرهاد  | i-PER                       | فرهاد  |
| O                          | را     | O                           | را     |
| JOB                        | شاعر   | b-JOB                       | شاعر   |
| O                          | دانسته | O                           | دانسته |
| O                          | است    | O                           | است    |
| O                          | .      | O                           | .      |

(جدول-۱): نمونه برچسب‌گذاری با مدل IO  
(Table-1): Labeling with IO model

| برچسب موجودیت نامدار | وازگان    |
|----------------------|-----------|
| PER                  | ملا       |
| PER                  | محمدمحسن  |
| PER                  | فیض       |
| PER                  | کاشانی    |
| DTE                  | ۱۰۵۸-۹۷۷  |
| DTE                  | هجری      |
| DTE                  | شمسی      |
| JOB                  | حکیم      |
| O                    | ,         |
| JOB                  | فیلسوف    |
| O                    | و         |
| JOB                  | عارف      |
| DTE                  | دوره      |
| DTE                  | صفوی      |
| O                    | و         |
| O                    | از        |
| PEG                  | دانشمندان |
| REL                  | شیعه      |
| O                    | است       |
| O                    | .         |

(جدول-۲): نمونه برچسب‌گذاری با مدل IOB  
(Table-2): Labeling with IOB model

| برچسب موجودیت نامدار | وازگان    |
|----------------------|-----------|
| b-PER                | ملا       |
| i-PER                | محمدمحسن  |
| i-PER                | فیض       |
| i-PER                | کاشانی    |
| b-DTE                | ۱۰۵۸-۹۷۷  |
| i-DTE                | هجری      |
| i-DTE                | شمسی      |
| b-JOB                | حکیم      |
| O                    | ,         |
| b-JOB                | فیلسوف    |
| O                    | و         |
| b-JOB                | عارف      |
| b-DTE                | دوره      |
| i-DTE                | صفوی      |
| O                    | و         |
| O                    | از        |
| b-PEG                | دانشمندان |



برای واژگانی که جزو موجودیت‌های نامدار نیستند، نیز علامتی در نظر گرفته شده است. گفتنی است این دادگان نخستین دادگان موجودیت‌های نامدار زبان فارسی با این تعداد تنوع در انواع موجودیت است. با توجه به این که استخراج اطلاعات از متن [37] و همچنین سامانه‌های پرسش و پاسخ [38] از جمله مهم‌ترین کاربردهای شناسایی موجودیت‌های نامدار است، درنظر گرفتن تنوع بیشتر در نوع موجودیت‌های نامدار کمک به سرایی در بهبود کیفیت و کارایی این سامانه‌ها خواهد داشت که این مهم با به کارگیری دادگان بالا محقق می‌شود.

## ۵-۲- مجموعه برچسب‌های پیشنهادی

واژگان گردآوری شده از ویکی‌پدیای فارسی برای آمورش سامانه نیازمند برچسب‌گذاری با نامدهایی است که هر کدام به یک نوع از موجودیت‌های نامدار اشاره دارد. تعداد کل برچسب‌های استفاده شده در دادگان ۳۱ برچسب است که برای مشخص کردن پاتزده نوع موجودیت متفاوت که شامل اسم شخص مفرد، اسم شخص جمع، موقعیت مکانی، اسم سازمان، زبان، ملیت، رخداد، شغل، کتاب، اسم فیلم، تاریخ، مذهب، عنوان علمی و دانش، روزنامه و سایر اسامی خاص بدانشده در زبان فارسی است، استفاده شده است. همچنین

(جدول-۴): راهنمای برچسب واژگان  
(Table-4): Vocabulary label Guide

| برچسب | برچسب             | تعریف انگلیسی     | تعریف فارسی<br>برچسب | توضیحات  | مثال   |
|-------|-------------------|-------------------|----------------------|--|--|
| O     | Օ՛՛               | Person            | هیچ                  | واژه مورد نظر از موجودیت‌های نامدار نیست.                        | ممکن<br>کوتاه<br>اوقات<br>ثبت‌نام  |
| P1I   | Person Individual | Person Individual | شخص مفرد             | این علامت به نام شخص اشاره دارد.                                 | سلطان محمود غزنوی<br>حسن روحانی  |
| P1G   | person Group      | person Group      | اسم خاص گروه         | این علامت به موجودیت نامداری اشاره دارد که به صورت جمع آمده است. | اعراب<br>شیعیان<br>صفاریان   |
| LOC   | Location          | Location          | موقعیت مکانی         | واژه مورد نظر این برچسب به موقعیت مکانی خاصی اشاره دارد.         | ایران<br>اراک<br>استان مرکزی   |
| ORG   | Organization      | Organization      | سازمان               | اسامی سازمان‌ها و مؤسسات مختلف با این برچسب نشان داده می‌شوند.   | فرهنگستان زبان و ادب فارسی<br>وزارت آموزش و پرورش<br>نیروی انتظامی<br>بانک مرکزی ایران |
| LAN   | Language          | Language          | زبان                 | این برچسب نشان دهنده زبان‌های مختلف است.                         | فارسی<br>يونانی<br>عربی  |
| NAT   | Nationality       | Nationality       | ملیت                 | ملیت‌های مختلف با این علامت تعیین می‌شوند.                       | ایرانی<br>يونانی   |
| EVN   | Events            | Events            | رخدادها              | رخدادها و وقایع خاص را با این برچسب نشان دادیم.                  | جام جهانی ۲۰۱۸<br>جنگ جهانی دوم<br>جشنواره فیلم فجر                                    |
| JOB   | Job               | Job               | شغل                  | این برچسب نمایان‌گر مشاغل است.                                   | اخترشناس<br>نویسنده<br>فیلسوف<br>معمار   |
| BOK   | Book              | Book              | کتاب                 | اسامی کتاب‌ها با این برچسب مشخص می‌شوند.                         | کتاب تاریخ بلغمی<br>لغت‌نامه دهخدا<br>منظمه ویس و رامین                                |
| FILM  | Film              | Film              | فیلم                 | نام فیلم‌های مختلف با این برچسب تعیین می‌شوند.                   | فیلم کارتوونی شیرشاه<br>بادپرگارد  |

|  |  |                |          |     |
|--|--|----------------|----------|-----|
| ۱۰ مهر ۶۱ قمری<br>سال ۱۳۷۰<br>قرن پنجم<br>دوره هخامنشیان | برای نشان دادن تاریخ و دوره های مختلف ازین برچسب استفاده شده است.  | تاریخ          | Date     | DTE |
| اسلام<br>کاتولیک<br>زرتشت<br>آیین بودا                   | این برچسب تعیین کننده مذاهب مختلف است.   | مذهب           | Religion | REL |
| اقتصادی<br>زمین‌شناسی<br>ریاضی                           | زمینه ها و دانش های مختلف با این برچسب تعیین گردیده است.   | زمینه          | Field    | FLD |
| روزنامه صور اسرافیل<br>روزنامه گاردین<br>تاپیمز          | اسمی روزنامه ها و مجلات با این برچسب آمده است.   | روزنامه و مجله | Magazine | MAG |
| هیدر روژن<br>عطارد<br>ساکسوفون<br>سیستم عامل لینوکس      | اگر واژه ای به عنوان موجودیت نامدار باشد، ولی در بین موجودیت های معروف شده در بالا نباشد با این برچسب مشخص می شود. | سایرین         | Other    | OTH |

(جدول-۵): مثال اول از جمله برچسب خورده دادگان

(Table-5): First example from tagged data

| واژگان | برچسب ها  |
|--------|-----------|
| b-BOK  | کتاب      |
| i-BOK  | ویس       |
| i-BOK  | و         |
| i-BOK  | رامین     |
| O      | از        |
| O      | شاهکارهای |
| O      | ادب       |
| b-LAN  | فارسی     |
| O      | و         |
| O      | اثر       |
| b-PEI  | فخر الدین |
| i-PEI  | اسعد      |
| i-PEI  | گرگانی    |
| b-JOB  | شاعر      |
| b-DTE  | قرن       |
| i-DTE  | پنجم      |
| i-DTE  | هجری      |
| O      | است       |

در این مقاله، برای تعیین اسم خاص اشخاص از دو برچسب مختلف استفاده شده است که یکی برای تعیین اسمی خاص مفرد و معمول به کار می رود و با علامت PEI<sup>۱</sup> مشخص شده است و دیگری برای اسمی خاص که به صورت جمع استفاده می شوند، کاربرد دارد. این موارد با برچسب PEG<sup>۲</sup> مشخص شده است.

اسم شخص جمع به تمامی اسمی ای گفته می شود که اسم مفرد آن نوعی موجودیت باشد. به عنوان مثال واژگان مسلمان، معلم و ایرانی به ترتیب برچسب های مذهب، شغل و ملیت می گیرند و اسم جمع این واژگان یعنی مسلمانان، معلمان و ایرانیان PEG محسوب می شوند. همین طور واژه ابوالفضل بلغمی دارای برچسب PEI است و به طبع آن واژگان خاندان بلغمی و یا بلغمیان PEG هستند.

گفتنی است در نظر گرفتن اسمی مشاغل، مذاهب، اسم شخص جمع و ... از چالش های اصلی این پژوهش بوده است. اگرچه در برخی از دادگان این موارد لحاظ نمی شود، اما برای وسعت بخشیدن به کاربرد تشخیص موجودیت های نامدار در مواردی مانند سامانه های استخراج اطلاعات و یا سامانه های پرسش و پاسخ در نظر گرفتن این موارد مورد نیاز است تا حجم بیشتری از اطلاعات تحت پوشش این سامانه ها قرار گیرند.

جدول (۴) به تفضیل به شرح و بررسی برچسب های استفاده شده برای دادگان می پردازد.

برای نمونه، مثال هایی از جملات برچسب خورده در دادگان براساس برچسب های معرفی شده در جداول (۵ و ۶) نمایش داده شده اند.

<sup>۱</sup> Person Individual<sup>۲</sup> person Group

اساس‌نامه و یکی‌پدیا باشد؛ یعنی مطالب بی‌طرفانه و بدون پایمال کردن حق نشر دیگران نوشته شده باشند. مدیریت بررسی نوشتارها توسط خود کاربران انجام می‌شود. کسانی که در امر تکمیل این پروژه بی‌پایان مشارکت می‌کنند، به هم‌زبانان خود یاری می‌رسانده‌اند تا در گردآوری بی‌همتاًترین دانشنامه جهانی سهمی داشته باشند.

(جدول-۷): آمار برچسب‌های پیکره تهیه شده  
(Table-7): Statistics of the annotated dataset

| تعداد | برچسب |
|-------|-------|
| ۱۴۶۰  | PEI   |
| ۵۸۸   | PLG   |
| ۴۰۵۲  | LOC   |
| ۳۱۷   | ORG   |
| ۵۵۵   | LAN   |
| ۳۳۶   | NAT   |
| ۹۱    | EVN   |
| ۴۴۹   | JOB   |
| ۲۶۵   | BOK   |
| ۱     | FLM   |
| ۱۰۱۰  | DTE   |
| ۱۱۱   | REL   |
| ۷۰۳   | FLD   |
| ۲۱    | MAG   |
| ۳۱۷   | OTH   |

و یکی‌پدیای فارسی دو سال پس از شروع پروژه و یکی‌پدیای انگلیسی، در آذر ۱۳۸۲ (۱۹ دسامبر ۲۰۰۳) فعالیت خود را آغاز کرد و اکنون در رده هفدهم یکی‌پدیاهای قرار دارد و بزرگترین و یکی‌پدیای در میان زبان‌های خاورمیانه و زبان‌های راست به چه و بزرگترین دانشنامه فارسی محسوب می‌شود.

و یکی‌پدیای فارسی تا اول سال ۲۰۱۷ میلادی شامل مقالاتی است که توسط بسیاری از افراد در موضوعات مختلف منتشر شده است. پس از حذف مقالات با طول کمتر از پنجاه واژه، حدود ۲۶۱۰۰ سند در این دانشنامه موجود است و تعداد کل واژگان متمایز در این مجموعه حدود ۲۱۲۰۰۰ است.[39]

کل دادگان یادشده برای آموزش الگوریتم word2vec مورد استفاده قرار گرفته است و از روی این دادگان بردار بازنمایی واژگان برمبنای واژه و حروف واژه ساخته شده است. همچنین برای فراهم کردن مجموعه دادگان آموزش مورد نیاز این پژوهش از داده‌های یکی‌پدیای فارسی

(جدول-۶): مثال دوم از جمله برچسب خورده دادگان

(Table-6): second example from tagged data

| واژگان | برچسب‌ها  |
|--------|-----------|
| b-PEI  | محمد      |
| i-PEI  | قاضی      |
| i-PEI  | اسداللهی  |
| O      | (زاده)    |
| b-DTE  | مهر       |
| i-DTE  | ۱۳۰۳      |
| O      | در        |
| b-LOC  | تهران     |
| O      | -         |
| O      | درگذشته   |
| b-LOC  | ۲۰        |
| i-DTE  | آذر       |
| i-DTE  | ۱۳۸۲      |
| O      | در        |
| b-LOC  | (تهران)   |
| O      | هرمند     |
| b-NAT  | ایرانی،   |
| b-JOB  | نقاش      |
| O      | (پرتوه،)  |
| b-JOB  | مجسمه‌ساز |
| O      | و         |
| b-JOB  | خوشنویس   |
| O      | معاصر     |
| O      | است       |

آمار تعداد عبارتی که برچسب موجودیت‌های نامدار را به خود تخصیص داده‌اند در جدول (۷) گزارش شده است. گفتنی است این آمار در سطح عبارت است و در سطح واژه تعداد بالاتر است. به عنوان مثال تعداد عبارتی که برچسب سازمان دارند در جدول ۳۱۷ گزارش شده است، اما با توجه به اینکه بسیاری از عبارات از بیش از یک واژه تشکیل شده‌اند این تعداد عبارت معادل ۹۰۸ واژه است. درمجموع تعداد عبارات دارای برچسب موجودیت نامدار ۱۰۲۷۷ و تعداد کل واژه‌های دارای برچسب موجودیت ۱۹۴۲۶ است. تعداد کل واژه‌های بدون برچسب موجودیت نیز ۷۳۸۷۶ است.

### ۳-۵-۵- داده‌های یکی‌پدیا

و یکی‌پدیای دانشنامه‌ای همگانی و آزاد است؛ بدین معنی که همه می‌توانند به نوشتن و ویرایش نوشتارهای موجود در آن پردازند. البته این نوشتارها و ویرایش‌ها باید مطابق با

با توجه به دراختیارداشتن حدود نودهزار واژه برچسب‌گذاری شده برای ارزیابی سامانه حاضر، از هفتادهزار واژه این پیکره برای آموزش مدل استفاده شده است. دههزار واژه به عنوان داده اعتبارسنجی<sup>۱</sup> (جهت یافتن مقادیر مناسب برای پارامترهای شبکه عصبی) و دههزار واژه دادگان نیز جهت آزمون استفاده شده است.

**۱-۶- ابزارهای استفاده شده**  
در راستای انجام این پژوهش، از زبان برنامه‌نویسی پایتون<sup>۲</sup> و کتابخانه‌های مربوط به آن استفاده شده است. برای تبدیل واژگان به بردار (word2vec) از کتابخانه Gensim استفاده شده که از ابزارهای مدل‌سازی فضای بردار مبتنی بر پایتون هستند و توسط ریهک و پتر<sup>۳</sup> در سال ۲۰۱۰ به وجود آمدند[42]. همچنین Fasttext، یک کتابخانه قدرتمند C++ است که برای آموزش نمایندگی واژه استفاده شده است که بوجانسکی<sup>۴</sup> و همکارانش آن را در سال ۲۰۱۶ ابداع کردند. Gensim انتخاب خوبی است؛ زیرا اجازه می‌دهد مدل‌های مختلف در یک چارچوب مستقر شوند و آن‌ها در فرمت سازگار با پیاده‌سازی word2vec اصلی ذخیره کنند. همچنین از FastText استفاده شده است که یک کتابخانه کارآمد برای یادگیری نمایش واژگان با توجه به ویژگی‌های صرفی آنها است [28].

برای اجرای الگوریتم حافظه طولانی کوتاه‌مدت دو طرفه نیز یک ساختار سه‌لایه با یکصد سلول ایجاد و همچنین از ابزارهای مختلفی در راستای پیاده‌سازی مدل استفاده شده است که برخی از آن‌ها عبارتند از tensorflow، .scipy و zlib، python

**۲-۶- معیارهای ارزیابی**  
برای ارزیابی الگوریتم ارائه شده، از چهار معیار دقت،<sup>۵</sup> صحّت،<sup>۶</sup> فراخوانی<sup>۷</sup> و معیار F<sup>۸</sup> استفاده شده است. این چهار معیار از جمله معیارهای معتبر در ارزیابی روش‌های مختلف یادگیری مашین هستند.

یکی از نکات مهم در ارزیابی الگوریتم‌های مختلف یادگیری در نظر گرفتن تقابل میان معیارهای صحّت و فراخوانی است: با افزایش یکی از این دو معیار دیگری کاهش

استفاده شده است. بدین صورت که قسمت چکیده تعداد ۲۹۱۳ سند مختلف ویکی‌پدیا، به صورت تصادفی انتخاب شده و متن آنها به واژگان تشکیل‌دهنده آن شکسته و برای تک- تک واژگان برچسب‌های موجودیت نامدارشان معین می‌شود. تعداد داده برچسب‌گذاری شده در این پژوهش ۹۰۷۹۳ واژه است.

همان‌طور که پیش‌تر گفته شد، برای گردآوری دادگان برچسب‌گذاری شده از ویکی‌پدیای فارسی استفاده شده است، چون در این نوع داده ساختار جملات و متن به‌گونه‌ای است که اطلاعات مورد نیاز موجودیت‌های نامدار و اسمی خاص را بیشتر در بردارد، و یا به نحوی پیش‌تر به توضیح اطلاعات مرتبط با اسمی خاص می‌پردازد و به‌کمک آن دادگان غنی از موارد مختلف موجودیت‌های نامدار شناسایی می‌شود. همچنین علت انتخاب ویکی‌پدیا به عنوان دادگان مورد استفاده برای تعییه واژگان نیز هم‌استabودن نثر آن با داده برچسب‌گذاری شده است که براساس نتایج ارائه شده توسط هادیفر و ممتازی این هم‌خوانی نقش بهسزایی در نتایج خواهد داشت [40].

## ۶- آزمایش‌های صورت گرفته

برای بررسی و ارزیابی مدل استفاده شده در این مقاله، از الگوریتم‌ها و روش‌هایی استفاده شده است که به توضیح آن می‌پردازیم. همان‌طور که پیش‌تر به آن اشاره شد، ابتدا از الگوریتم word2vec برای به‌دست‌آوردن دو مدل بردار واژه به‌طول سیصد و بردار ویژگی حروف هر واژه به‌طول دویست استفاده شده است. طول این بردارها بر مبنای پیشنهادهای پژوهش‌های مختلف پیشین که از این بازنمایی‌ها استفاده کرده بودند، انتخاب شده است [41]. در این قسمت واژگان مشابه و هم‌ریشه، بردارهای شبیه به هم خواهند داشت. این الگوریتم از جمله روش‌های بدون نظارت است که برای آموزش از دادگان بدون برچسب ویکی‌پدیا استفاده کرده است؛ سپس از الگوریتم شبکه عصبی حافظه طولانی کوتاه‌مدت دو طرفه استفاده شده است. برای آموزش این شبکه از دادگان برچسب خورده و بردارهای مربوط به هر واژه و حروف که از قسمت قبلی به‌دست آمده است، استفاده می‌شود. بدین ترتیب، شبکه آموزش داده می‌شود و برای آزمایش شبکه عصبی پیاده‌سازی شده از داده‌های بدون برچسب و بردارهای به‌دست آمده مرحله نخست استفاده می‌شود.

فصلنامی

۱۴۱

<sup>1</sup> Validation Set<sup>2</sup> python<sup>3</sup> Rechurck and Petr<sup>4</sup> Bojanowski<sup>5</sup> Accuracy<sup>6</sup> Precision<sup>7</sup> Recall<sup>8</sup> F-Measure

**۶-۳-نتایج نهایی آزمایش‌ها**  
 نتایج به دست آمده از آزمایش‌های صورت گرفته بر روی داده‌ها به کمک روش شبکه عصبی حافظه طولانی کوتاه‌مدت دو طرفه و با استفاده از روش ارزیابی‌ای که از هفتادهزار داده برای آموزش مدل، دههزار داده برای اعتبارسنجی و دههزار داده نیز جهت آزمون استفاده شده است در جدول (۸) نمایش داده شده است. ضمن اینکه آزمایش‌ها بر مبنای مدل اعتبارسنجی مقاطعه<sup>۵</sup> تکرار شده‌اند.

(جدول-۸): نتایج پر اساس استفاده از هفتادهزار داده برای آموزش

(Table-8)Results based on the use of 70000 data for training

|           | Word Embedding | Character Embedding |
|-----------|----------------|---------------------|
| F-measure | 70.53          | 72.09               |
| Precision | 73.28          | 74.74               |
| Recall    | 67.98          | 69.63               |
| Accuracy  | 91.58          | 92.23               |

همان‌طور که در نتایج مندرج در این جدول مشاهده می‌شود، نتایج حاصل از استفاده از بردار word2vec با ویژگی حروف بهتر از بردار برمبنای واژه بوده است. این امر نشان می‌دهد، شباهت معنایی واژگان به تنها یکی کافی نیست و در نظر گرفتن شباهت واژگان بر مبنای ویژگی‌های صرفی نیز از اهمیت ویژه‌ای برخوردار است.

برای تحلیل خطاهای مطرح در داده جدول آشنگی نتایج نیز برای تمام برچسب‌های موجود استخراج شده است که در جدول (۹) نمایش داده شده است.

همان‌طور که در نتایج این جدول مشخص است، در بیشتر موارد روش پیشنهادی برچسب صحیح را انتخاب کرده است. بیشترین خطاهای در تشخیص شروع و میانه مکان‌ها (b-I.OC, i-I.OC) و شروع و میانه اسامی اشخاص (b-PEI, i-PEI) مشاهده می‌شود. یکی از دلایل این خطا پیچیدگی ساختار زبانی در تشخیص محل صحیح شروع عبارات اسامی است. به عنوان مثال عبارت "جهان پهلوان رستم" در داده‌های این پژوهش برچسب اسامی شخص گرفته است. به این صورت که واژه "جهان" شروع عبارت و واژه‌های "پهلوان" و "رستم" میانه عبارت هستند؛ در حالی که مدل

<sup>5</sup> Cross-Validation

خواهد یافت. از طرفی برای محاسبه میانگین این دو معیار میانگین ریاضی مناسب نیست و اطلاعات کافی از آن استخراج نخواهد شد. به همین جهت از میانگین هارمونی یا معیار F برای ارزیابی بهتر استفاده می‌شود. معیارهای بالا نیاز به محاسبه مقادیر چهارگانه جدول آشنگی دارند که این مقادیر برای هر موجودیت بدین صورت محاسبه می‌شود: مقدار مثبت درست<sup>۱</sup> عبارت است از تعداد دفعاتی که یک نمونه به صورت صحیح برچسب موجودیت مدنظر را دریافت کرده است. مقدار مثبت نادرست<sup>۲</sup> عبارت است از تعداد دفعاتی که یک نمونه برچسب موجودیت را به اشتباه دریافت کرده است (خواه آن نمونه به هیچ وجه موجودیت نبوده، خواه موجودیت بوده اما از نوع دیگری). مقدار منفی درست<sup>۳</sup> به تعداد دفعاتی اشاره دارد که یک نمونه که موجودیت نامدار نیست برچسب موجودیت نامدار را دریافت نکرده است و مقدار منفی نادرست<sup>۴</sup> به تعداد دفعاتی اشاره دارد که یک نمونه می‌باشد برچسب موجودیت هدف را دریافت می‌کرده اما به اشتباه یا به هیچ وجه به عنوان موجودیت تشخصیض داده نشده با نوع دیگری از موجودیت به آن تشخصیض یافته است.

فرمول‌های محاسبه هر کدام از این چهار معیار یادشده در زیر آمده است:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

$$F - \text{measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4)$$

گفتنی است در محاسبات انجام شده، برچسب یک نمونه تنها در صورتی صحیح قلمداد می‌شود که علاوه بر تشخیص موجودیت نامدار، نوع آن نیز به صورت صحیح تشخیص داده شود.

<sup>1</sup> True Positive(TP)

<sup>2</sup> False Positive (FP)

<sup>3</sup> True Negative (TN)

<sup>4</sup> False Negative (FN)

پیشنهادی تنها واژه "رستم" را به عنوان موجودیت تشخیص داده و به آن برچسب شروع عبارت داده است. و یا در جمله آنتاریو از لحاظ جمعیت قویترین استان کانادا است"، برخلاف این که واژه "کانادا" به تنهایی یک عبارت اسمی مکان می باشد، اما روش پیشنهادی به اشتباه عبارت "استان کانادا" را به عنوان اسم مکان تشخیص داده است. در نتیجه برچسب صحیح شروع عبارت برای واژه "کانادا" به اشتباه

(جدول-۹): جدول آشیانگی نتایج  
(Table-9): Confusion Matrix of the Results

اعتبارسنجی و دههزار داده به عنوان آزمون استفاده شده و نتایج به دست آمده برای مدل مبتنی بر بردار حروف در جدول (۱۲) آمده است.

(جدول-۱۲): نتایج بر اساس استفاده از هفتادهزار داده با در تعداد بروچسب‌های کمتر می‌توان با دقت بالاتری موجودیت‌های متن را تشخیص داد. البته بدینهی است که سایر بروچسب‌های متنوع استفاده شده در این دادگان از اهمیت به سزاوی برخوردارند و در کاربردهای مختلف تشخیص موجودیت‌های نامدار این بروچسب‌ها می‌توانند تأثیر مهمی در کارایی سامانه داشته باشند. در نهایت با استناد به این نتایج می‌توان نتیجه‌گیری کرد که بنا بر کاربرد مدل پیشنهادی حاضر در سامانه‌های مختلف پردازش زبان طبیعی می‌توان در مورد انتخاب ساختار بروچسب‌گذاری دادگان تصمیم‌گیری مناسب داشت.

(جدول-۱۳): نتایج بر اساس استفاده از هفتادهزار داده با در نظر گرفتن سه بروچسب PER، LOC و ORG

(Table-12): Results based on the use of 70000 data with the consideration of the three PER, LOC and ORG labels

|           | Character Embedding |
|-----------|---------------------|
| F-measure | 74.28               |
| Precision | 77.75               |
| Recall    | 71.1                |
| Accuracy  | 94.88               |

## ۷- نتیجه‌گیری

در مقاله حاضر، روشی برای تشخیص موجودیت‌های نامدار در زبان فارسی ارائه شده است که مبتنی بر تبدیل واژه به بردار و ایجاد بردارهای بازنمایی واژگان بر مبنای واژه و همچنین حروف واژه بر مبنای شبکه عصبی است. در روش پیشنهادی که بر مبنای الگوریتم شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه عمل می‌کند، شبکه با دادگان بروچسب‌خورده و بردارهای به دست آمده از الگوریتم word2vec آموزش داده می‌شود. نتایج حاصل از ارزیابی به کمک معیارهای دقت، صحت، فراخوانی و معیار F نشان می‌دهد، استفاده از روش بردار بازنمایی ویژگی حروف واژه دقت بالاتری را در بردارد که به بهبود روش تشخیص

در بخش دیگری از آزمایش‌های به بررسی اهمیت حجم داده تهیه شده در این پژوهش پرداخته شده است. برای این بررسی، ارزیابی کارایی سامانه طراحی شده با تعداد کمتری داده آموزش تکرار شده است. به این معنا که به جای استفاده از هفتادهزار داده آموزش در یک مرحله، تنها چهل هزار واژه و در مرحله دیگر تنها بیست هزار واژه به عنوان داده آموزش در نظر گرفته شده است. جداول (۱۰) و (۱۱) حاصل این بررسی را نمایش می‌دهند.

(جدول-۱۰): نتایج بر اساس استفاده از چهل هزار داده برای آموزش

(Table-10): Results based on the use of 40,000 data for training

|           | Word Embedding | Character embedding |
|-----------|----------------|---------------------|
| F-measure | 65.33          | 68.37               |
| Precision | 69.11          | 72                  |
| Recall    | 61.93          | 65.09               |
| Accuracy  | 90.32          | 90.72               |

(جدول-۱۱): نتایج بر اساس استفاده از بیست هزار داده برای آموزش

(Table-11): Results based on the use of 20,000 data for training

|           | Word embedding | Character embedding |
|-----------|----------------|---------------------|
| F-measure | 61.34          | 60.99               |
| Precision | 65.69          | 66.93               |
| Recall    | 57.53          | 56.02               |
| Accuracy  | 88.79          | 88.55               |

با توجه به نتایج به دست آمده در دو جدول (۱۰) و (۱۱)، می‌توان به این نتیجه دست یافت که افزایش تعداد دادگان بروچسب‌خورده و بالابودن حجم دادگان تولید شده می‌تواند در تشخیص موجودیت‌های نامدار مؤثر باشد و دقت بالاتری را به دست آورد. این امر خود مبین این است که با قراردادن تلاش بیشتر بر روی مقوله بروچسب‌دهی دادگان می‌توان دقت سامانه حاضر را باز هم افزایش داد.

در گام آخر ارزیابی سامانه، به بررسی تأثیر تنوع بالای بروچسب‌ها در دقت سامانه تشخیص موجودیت‌های نامدار پرداخته شده است. برای بررسی این امر در دادگان یادشده، به جای پانزده بروچسب موجودیت‌های نامدار، تنها از سه بروچسب PER، LOC و ORG استفاده شده است و سایر بروچسب‌ها حذف شده است. همچنین در ارزیابی از هفتادهزار داده به منظور آموزش شبکه، دههزار داده برای

- [8] S. Morwal, N. Jahan and D. Chopra, "Named Entity Recognition using Hidden Markov Model (IIMM)" *International Journal on Natural Language Computing (IJNLC)*, Vol.1, No.4, pp. 15-23, 2012.
- [9] C. Lee, Y. Hwang, H. Oh, S. Lim, J. Heo, C. Lee, H. Kim, J. Wang, M. Jang, "Fine-Grained Named Entity Recognition Using Conditional Random Fields for Question Answering", *Asia Information Retrieval Technology, Lecture Notes in Computer Science*, vol 4182, 2006.
- [10] S. Özkaya and B. Diri, "Named Entity Recognition by Conditional Random Fields from Turkish informal texts", *IEEE 19th Signal Processing and Communications Applications Conference (SIU)*, pp. 662-665, 2011.
- [11] Y. Benajiba and P. Rosso, "Arabic Named Entity Recognition using Conditional Random Fields", *Workshop on HLT&NLP within the Arabic World, LRFC*, 2008.
- [12] A. Ekbal and S. Bandyopadhyay, "A Conditional Random Field Approach for Named Entity Recognition in Bengali and Hindi". *Linguistic Issues in Language Technology (LiLT)*, Volume (2:1), pp. 1-44, CSII Publication, 2009.
- [13] J.R. Curran and S. Clark. 2003, "Language independent NER using a maximum entropy tagger", *Seventh conference on Natural language learning at HLT-NAACL, Association for Computational Linguistics*, pp. 164-167, 2003.
- [14] L. Li, L. Jin, Z. Jiang, D. Song and D. Huang, "Biomedical named entity recognition based on extended Recurrent Neural Networks", *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pp. 649-652, 2015.
- [15] N. Suakkaphong, Z. Zhang, H. Chen, "Disease named entity recognition using semisupervised learning and conditional random fields", *Journal of the American Society for Information Science and Technology*, Vol. 62, Issue 4, 2011.
- [16] Q. Wei, T. Chen, R. Xu, Y. He, L. Gui, "Disease named entity recognition by combining conditional random fields and bidirectional recurrent neural networks", *journal of biological data-bases and curation*, 2016.
- [17] پ. مرتضوی و م. شمس‌فرد، «شناسایی موجودیت‌های نامدار در متون فارسی». پانزدهمین کنفرانس بین‌المللی سالانه انجمن کامپیوتر ایران.

موجودیت نامدار کمک می‌کند. بر اساس آزمایش‌های انجام‌گرفته مشاهده می‌شود که افزایش تعداد دادگان نقش بهسزایی در بالابدن دقت سامانه دارد. همچنین بالابدن تعداد برچسب‌های مورد استفاده باعث افزایش پیچیدگی مدل می‌شود.

گفتنی است که در این مقاله گامی بزرگ در راستای تشخیص موجودیت‌های نامدار در زبان فارسی برداشته شده است؛ چرا که با برچسب‌زنی مجموعه سه‌هزار چکیده از پیکره ویکی‌پدیای فارسی که شامل نودهزار واژه است با مشخص کردن پانزده موجودیت مختلف در دادگان، به غنی‌سازی دادگان فارسی می‌پردازد. با توجه به نامتوازن بودن داده آموزشی در تشخیص موجودیت‌های نامدار، استفاده از مدل‌های پیشرفته‌تر از جمله مدل‌هایی که در آن تمایل به تابع هزینه شبکه عصبی اضافه می‌شود از جمله کارهای آینده این پژوهش خواهد

## ۸- References - مراجع

- [1] Y. Chen, T.A. Lasko, Q. Mei, J.C. Denny and H. Xu, "A study of active learning methods for named entity recognition in clinical text", *Journal of Biomedical Informatics*, 2015.
- [2] Z.S. Abdallaha, M.Carmana and Gh. H7affari, "Multi-domain evaluation framework for named entity recognition tools", *Computer Speech & Language*, 2017.
- [3] S. Hussain, J.J. K. and G.C. Hazarika, "The First Step Towards Named Entity Recognition in Missing Language", *International Conference on Electrical, Electronics, and Optimization Techniques*, 2016.
- [4] D.Jurafsky, and M.James II, "Speech and Language Processing: An Introduction to Natural Language Processing, Speech Recognition", Prentice Hall, 2009.
- [5] C.Santos, B.Zadrozny, "Learning Character-level Representations for Part-of-Speech Tagging", *International Conference on Machine Learning*, 2014.
- [6] O.Moradiannasab, S.Momtazi and A.Palmer, "A Named Entity Recognition Tool for Persian", In Proceedings of the 3rd Iranian Conference on Computational Linguistics, 2014.
- [7] F.Erik, K.S.Tjong, & D.M.Fien, "Introduction to the CoNLL-2003 Shared Task: Language-Independent Named Entity Recognition", *Proceedings of CoNLL-2003*, pp. 142-147, 2003.





- [26] T. Mikolov, K.Chen, G.Corrado, J.Dean, "Efficient Estimation of Word Representations in Vector Space", arXiv preprint arXiv:1301.3781, 2016.
- [27] C.N.dos Santos and V.Guimaraes, "Boosting Named Entity Recognition with Neural Character Embeddings", Proceedings of the Fifth Named Entity Workshop, 2015.
- [28] P.Bojanowski, E.Grave, A.Joulin, and T.Mikolov, "Enriching Word Vectors with Subword Information", Transactions of the Association for Computational Linguistics, 5:135–146, 2017.
- [29] R. Socher, Ch. D. Manning and A.Y. Ng, "Learning Continuous Phrase Representations and Syntactic Parsing with Recursive Neural Networks", Proceedings of the NIPS-2010 Deep Learning and Unsupervised Feature Learning Workshop, 2010.
- [30] Phong Le and Willem II. Zuidema, "Compositional Distributional Semantics with Long Short Term Memory", Proceedings of the Fourth Joint Conference on Lexical and Computational Semantics, 2015.
- [31] S. Hochreiter and J. Schmidhuber, Long Short-Term Memory, Neural Computing, vol.9 (8), 1997.
- [32] G.Lample, M.Ballesteros, Sandeep Subramanian, K.Kawakami and Ch.Dyer, "Neural Architectures for Named Entity Recognition", Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016.
- [33] Poostchi, Hanich, Ehsan Zare Borzeshi, Mohammad Abdous and Massimo Piccardi, "PersoNER: Persian Named-Entity Recognition.", COLING, 2016.
- [34] M. Ghayoomi, "Bootstrapping the development of an HPSG-based treebank for Persian," Linguistic Issues in Language Technology, vol.7, no.1, 2012.
- [35] J.R. Finkel, T.Grenager and Ch.Manning, "Incorporating Non-local Information into Information Extraction Systems by Gibbs Sampling", Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics, pp. 363-370, 2005.
- [36] M. Konkol, M. Konopík, "Segment Representations in Named Entity Recognition". International Conference on Text, Speech, and Dialogue (TSD), Lecture Notes in Computer Science, vol 9302. Springer, 2015.
- [17] P. Mortazavi and M. Shamsfard, "Named Entity Recognition in Persian Texts", The 15th National CSI Computer Conference, 2009.
- [18] M. Kolali Khormuji and M. Bazrafkan, "Persian named entity recognition based with local filters", International Journal of Computer Applications 100(4), 2014.
- [19] M. Bijankhan, J. Sheykhzadegan, M. Bahrani, and M. Ghayoomi, "Lessons from building a Persian written corpus: Peykare", *Language resources and evaluation*, 45(2), pp. 143–164, 2011.
- [۲۰] ام. عبدالوس، ب. مینایی بیدگلی. "بهبود شناسایی موجودیت‌های نامدار فارسی با استفاده از کسره اضافه." پردازش علائم و داده‌ها. ۱۴ (۴) ۱۳۹۶ ۵۴-۴۳:
- [20] M. Abdoos, B. Manaci, "Improving Named Entity Recognition Using Izafe in Farsi", *JSDP*, vol.14 (4), pp.43-54, 2018.
- [21] F. Ahmadi and H. Moradi, "A hybrid method for Persian named entity recognition", *The IEEE Conference on Information and Knowledge Technology (IKT)*, pp. 1-7, 2015.
- [22] H. Poostchi, E.Z. Borzeshi, M. Abdous, and M. Piccardi, "PersoNER: Persian named-entity recognition", International Conference on Computational Linguistics (COLING), 2016.
- [23] K. Dashtipour, M. Gogate, A. Adeel, A. Algarafi, N. Howard, and A. Hussain, "Persian Named Entity Recognition", *IEEE International Conference on Cognitive Informatics & Cognitive Computing*, pp. 79–83, 2017.
- [۲۴] آ. شاکری، م. شهرشانی، ه. فیلی، م. محسنی، م. ملاعباسی، «تشخیص موجودیت‌های اسمی در زبان فارسی». گزارش فنی، SE-P18-MGT-PRS-01-v2 ۱۳۹۷ مرکز تحقیقات مخابرات ایران،
- [24] A. Shakeri, M. Shahshahani, H. Feili, M. Mohseni, and M. Molla Abbasi., "Persian Language Processing Tools (Research on Named Entity Recognition Tools in Natural Language and Presentation of a Laboratory Instance for Persian)", Technical Report SE-P18-MGT-PRS-01-v2.0. Iran Telecommunication Research Center, 2017.
- [25] J. Turian, L. Ratinov, and Y. Bengio, "Word representations: a simple and general method for semi-supervised learning", In *Proceedings of the 48th Annual Meeting of the Association*

تهران. انجمن کامپیوتر. مرکز توسعه فناوری نیرو.

۱۳۸۸



فرزانه ترابی دارای مدرک مهندسی کامپیوتر از دانشگاه صنعتی شاهروド و فارغ‌التحصیل کارشناسی ارشد هوش مصنوعی دانشگاه صنعتی امیرکبیر است. اوی پایان‌نامه کارشناسی ارشد خود را در آزمایشگاه پردازش زبان طبیعی دانشگاه امیرکبیر و در زمینه تشخیص موجودیت‌های نامدار فارسی با استفاده از روش‌های یادگیری عمیق به انجام رسانده است. نشانه، ابانامه اشان، عبارت است از:

f9torabi@gmail.com

- [37] S. Momtazi and O. Moradiannasab, "A Statistical Approach for Knowledge Discovery: Bootstrapped Analysis of Language Models for Knowledge base Population from Unstructured Text". *Scientia Iranica* 26 (Special Issue on: Socio-Cognitive Engineering), pp. 26-39, 2019.
  - [38] S. Momtazi and D. Kalkow, "Bridging the Vocabulary Gap between Questions and Answer Sentences". *Information Processing & Management*, 51 (5), 2015.
  - [39] <https://fa.wikipedia.org,96.05.25>.
  - [40] A. Hadifar, S. Momtazi, "The Impact of Corpus Domain on Word Representation: a Study on Persian Word Embeddings", *Lang Resources & Evaluation*, 52(4), pp. 997–1019, 2018.
  - [41] Z. Bairong, W. Wenbo, L. Zhiyu, Z. Chonghui, T. Shinozaki, "Comparative Analysis of Word Embedding Methods for DSTC6 End-to-End Conversation Modeling Track", *Proceedings of International Conference of Dialog System Technology Challenges*, 2017.
  - [42] R.Rchurck and S.Pctr, "Software Framework for Topic Modelling with Large Corpora", *In Proceedings of LREC2010 Workshop on New Challenges for NLP Frameworks*, pp. 45–50, 2010.



سعیده ممتازی در حال حاضر استادیار دانشکده مهندسی کامپیوتر دانشگاه صنعتی امیرکبیر است. وی سرپرستی آزمایشگاه پردازش زبان طبیعی را بر عهده دارد. ایشان دوره کارشناسی و کارشناسی ارشد خود را در دانشگاه صنعتی شریف گذرانده و سپس دوره دکترا را در دانشگاه زارلیند آلمان سپری کرده است. وی به عنوان فرست مطالعاتی بخشی از تحصیل دکترای خود را در دانشگاه جان هاپکینز آمریکا گذرانده و پس از اتمام دوره دکترا به عنوان پژوهش گر پساد کترا در دانشگاه پتسدام آلمان و همچنین مؤسسه تحقیقات آموزشی آلمان به پژوهش پرداخته است. زمینه اصلی فعالیت او پردازش زبان طبیعی است.

نشنانی رایانمه ایشان عبارت است از:  
[momtazi@aut.ac.ir](mailto:momtazi@aut.ac.ir)