

## تشخیص مکاتب فلسفی با استفاده از یادگیری عمیق

احمد علی محمدی<sup>۱</sup>، محمدمهدی حسینی<sup>۲\*</sup>

<sup>۱</sup>دانشکده مهندسی کامپیوتر، واحد شاهرود، دانشگاه آزاد اسلامی، شاهرود، ایران

<sup>۲</sup>دانشکده مهندسی کامپیوتر، واحد شاهرود، دانشگاه آزاد اسلامی، شاهرود، ایران

### چکیده

در حوزه شناخت مکاتب فلسفی، تفکر هر شخص با توجه به نوع نگرشی که در خصوص مکاتب مختلف می تواند داشته باشد متفاوت است. تشخیص نگرش نویسنده و میزان شباهت آن به هر کدام از مکاتب فلسفی همواره یکی از موضوعات مهم در حوزه علوم انسانی بوده است. در این مقاله، روشی مبتنی بر یادگیری عمیق برای تشخیص مکاتب فلسفی از روی متن پیشنهاد شده است. در روش پیشنهادی، ابتدا متن ها نرمال شده و کلمات اضافی و فاقد معنا حذف می شوند. بعد از مرحله نرمال سازی، متن به جملات و کلمات شکسته شده و سپس با استفاده از کتابخانه فست تکست هر کلمه به بردار عددی تبدیل می شوند، پس از آن با استفاده از شبکه طراحی شده ویژگی های متون استخراج شده و در نهایت سیستم، متون را یاد گرفته و آماده برای استخراج داده ها می باشد و با دادن یک جمله جدید میزان شباهت آن به هر مکتب بیان می شود. بر اساس ارزیابی صورت گرفته، میزان دقت در روش پیشنهادی ۹۴ درصد می باشد.

### مقاله پژوهشی

تاریخ دریافت:

۱۴۰۲/۰۴/۰۴

تاریخ پذیرش:

۱۴۰۲/۰۸/۳۰

کلیدواژه‌ها:

مکاتب فلسفی، داده کاوی متن، تشخیص مکاتب، تبدیل متن به بردار عددی، میزان شباهت تفکر نویسنده با مکاتب

نویسنده مسئول:

hosseini\_mm@yahoo.com

doi : 10.22034/ABMIR.2023.20250.1029

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2023.20250.1029) /© 2023. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).





## ۱- مقدمه

فلسفه، واژه‌ای با ریشه یونانی و معرب فیلسوفیا به معنای دوستدار دانش است [۱]. به بیانی دیگر در فلسفه فعالیت فکری و ذهنی در زمینه موضوعات و مسائل بنیادینی از حیطه علوم تجربی خارج بوده و با روش تجربی قابل اثبات یا رد نبوده و تابع قرارداد و اعتبار نیست و با روش نقلی اثبات نمی‌شود. بنیادی‌ترین مسئله در اندیشه نوع بشر، پرسش از هستی و واقعیت است که قدمتی به درازای اندیشیدن و تعقل دارد. به همین مناسبت فیلسوفان مسلمان از ابونصر فارابی و ابن سینا تا فلاسفه متأخر، همگی فلسفه را دانشی دانسته‌اند که در آن از احوال هستی و واقعیت از جهت واقعیت‌مندی یا پنداری بودن آن، مورد بحث قرار می‌دهند [۲] [۳]. در تحقیقات گذشته در زمینه علوم انسانی مکاتب فلسفه، از دیدگاه‌های مختلف مورد بررسی قرار گرفته است. گرایش‌های متفاوتی در مکتب‌های فلسفی از قبیل فلسفه سیاسی، فلسفه اجتماعی، فلسفه اخلاقی و غیره که هر کدام دارای ایدئولوژی منحصر به فرد خود هستند وجود دارد. با ظهور هوش مصنوعی در قرن جدید می‌توان در بسیاری از زمینه‌ها از این تکنولوژی بهره گرفت. در این راستا، چهار مکتب فلسفی سوسیالیسم، سکولاریسم، لیبرالیسم و مارکسیسم، برای ارائه روش پیشنهادی مورد استفاده قرار گرفت. امروزه استفاده از روش‌های مبتنی بر یادگیری عمیق در هنگام کار با متون بسیار بزرگ و حجیم یک رویکرد جذاب و کاربردی است. یادگیری عمیق و تمام جنبه‌های هوش مصنوعی مدرن از داده‌ها استفاده می‌کنند تا تصمیم‌های مشابه هوش انسانی بگیرند. یکی از کاربردهای اصلی یادگیری عمیق، استفاده از آن در حوزه داده کاوی می‌باشد. امروزه با پیشرفت‌های صورت گرفته در پردازش اطلاعات و همچنین دسترسی رایگان به متون دیجیتالی، بررسی حجم عظیمی از متون فلسفی به منظور یافتن اطلاعاتی که در این متون هستند به سادگی امکان‌پذیر می‌باشد. با استفاده از یادگیری عمیق و تکنیک‌های داده کاوی می‌توان حجم عظیمی از داده و اطلاعات را به سیستم آموزش داده و اطلاعاتی سودمند بر اساس نیاز استخراج و بهره‌بردارای‌های لازم را انجام داد. آنچه در این مقاله بررسی می‌شود یادگیری متون مکاتب فلسفی و سپس میزان

شباهت متون جدید به هر کدام از مکاتب بر اساس آنچه یاد گرفته شده است می‌باشد. از جمله نتایج حاصل از این مقاله به بهره‌وری کامل تر از منابع موجود در مکاتب فلسفی، استفاده از منابع بیشتر در مدت زمان کمتر، استفاده سریع تر و آسان تر از منابع، مقایسه و شناخت شباهت متون با یکدیگر، تشخیص متن نویسنده و شناخت شباهت متن به متون موجود در پایگاه داده می‌توان اشاره کرد. در این مقاله در بخش دوم مروری بر کارهای گذشته صورت گرفته است. در بخش سوم به بیان روش پیشنهادی خواهیم پرداخت. در بخش چهارم ارزیابی از روش پیشنهادی خواهیم داشت و در فصل پنجم به نتیجه‌گیری و کارهایی که در آینده قابل انجام خواهد بود اشاره شده است.

## ۲- مروری بر کارهای گذشته

در پژوهشی باتوجه به اهمیت تکنیک‌های موثر و کارآمد پردازش زبان، به مروری بر روندها و تکنیک‌های پردازش زبان طبیعی با استفاده از NLTK پرداخته شده است [۴]. در پژوهشی دیگر به محاسبه خودکار معیارهای غنی واژگانی برای یادگیری L2 با مقایسه ابزارهای NLTK، LCA و SpaCy پرداخته شده است [۵]. همچنین برای طبقه‌بندی موضوعی اسناد با استفاده از مجموعه‌ای از مقالات و یکی پدیا روشی مبتنی بر یک شبکه LSTM با اسنادی که به صورت دنباله‌ای از کلمات کدگذاری شده و با بردارهای ورد تو وک<sup>۱</sup> ایجاد گردیده ارائه نموده است. ارزیابی و آزمایشات آنها نشان داد که رویکرد ارائه شده نسبت به یک رویکرد استاندارد و کیفی کلمه با اسناد که از TF-IDF استفاده نموده باشد بهتر عمل کرده است [۶]. در پژوهشی دو تکنیک CBOW و اسکپ گرام<sup>۲</sup> برای تولید مدل‌های جاسازی کلمات، دقیق و کارآمد شناخته شده و در این مورد با بهره‌گیری این دو تکنیک که توسط Mikolov [۷] پیشنهاد شده، یک نسخه کاملاً بهینه شده از این مدلها را با استفاده از Py-Torch پیاده‌سازی کردند و در تجزیه و تحلیل احساسات در موضوع اسباب بازی بکار گرفتند [۸].

<sup>۲</sup> Skip-gram

<sup>۱</sup> Word2vec

ماشین مرسوم دارای مشکلاتی مانند مشکل ابعاد و کارایی پایین هستند، یک مدل طبقه بندی متن بر اساس فست تکست را پیشنهاد می‌کند، که در این مدل اطلاعات مهم موجود در متن را از طریق مهندسی ویژگی بررسی کرده است. این بررسی از پایتون برای طبقه‌بندی مجموعه داده متنی (تشخیص محتوای عاطفی نظر کاربران) در پلتفرم بایدو دپانسی است [۱۳].

### ۳- روش پیشنهادی

در روش پیشنهادی ابتدا داده‌ها با استفاده از کتابخانه هضم<sup>۲</sup> پیش پردازش می‌شوند، سپس هر متن با توجه به عنوانی که دارد در مجموعه داده مخصوص خود قرار می‌گیرد و بعد از آن داده‌ها به دو دسته آموزش و آزمون تقسیم می‌شوند، در مرحله بعد آنها را تبدیل به بردارهای عددی کرده و پس از آن اقدام به استخراج ویژگی‌های مورد نیاز از بردارهای عددی ساخته شده بر مبنای مدل می‌گردد. پس از یادگیری، سیستم ارزیابی شده و نتیجه بررسی می‌شود. شکل (۱) فلوچارت روش پیشنهادی را نمایش می‌دهد.

#### ۳-۱- پایگاه داده

با توجه به جدید بودن موضوع در روش پیشنهادی، پایگاه داده استاندارد برای این مهم وجود نداشت. بنابراین نیاز به جمع‌آوری متن‌های مرتبط با این موضوع بود. با بررسی‌های صورت گرفته، متون پایگاه داده از پژوهشگاه علوم انسانی و مطالعات فرهنگی جمع‌آوری شد. در مجموعه داده جمع‌آوری شده چهار مکتب مورد بررسی قرار گرفت. جدول ۱ تعداد کلمات مربوط به هر مکتب را نشان می‌دهد.

جدول (۱): تعداد کلمات هر مکتب

نام مکتب	تعداد کلمه
سکولاریسم	۳۰۷۲۰
سوسیالیسم	۳۳۷۱۴
مارکسیسم	۱۵۳۵۴
لیبرالیسم	۲۸۶۹۲

در پژوهشی دیگر به مقایسه دو، مدل CBOW و مدل اسکپ گرام پرداخته و نتیجه گرفته، مدل اسکپ گرام دارای دقت بالایی در نمایش توزیع کلمات است، اما یادگیری آن زمان زیادی طول می‌کشد. از سوی دیگر، مدل CBOW در نمایش توزیع کلمات سریع تر اما از دقت کمتری نسبت به مدل اسکپ گرام برخوردار است. در این مطالعه، روشی را برای ترکیب مدل CBOW و مدل اسکپ گرام به شیوه ای پیشنهاد داده که ماتریس وزن مدل CBOW را با مدل اسکپ گرام به اشتراک می‌گذارد تا هم سرعت یادگیری و هم دقت نمایش توزیع را بدست بیاورد [۹]. در این پژوهش ایده ای، برای حل مشکل خوشه بندی پیشنهاد شده است. که در مرحله اول از جاساز کلمات استفاده شده، که ویژگی معنایی کلمات را به همراه اطلاعات دستوری و نحوی به ارمغان می‌آورد و در مرحله بعد، اسناد به عنوان مجموع وزنی TF-IDF بردارهای تعبیه شده مربوط به هر کلمه نشان داده می‌شوند. وزن بیشتر TF-IDF به این معنی است که کلمات در اسنادی که در آنها آمده است رابطه قوی تری دارند. در نهایت، با استفاده از خوشه بندی سلسله مراتبی، تمام اسناد نوشته شده توسط هر نویسنده را با یکدیگر گروه بندی می‌کند [۱۰].

برای دسته بندی متون، هر متن با توجه به عنوان و میزان شباهتی که با داده های هم نوع دارند دسته بندی می‌شوند. در این روش الگوریتم‌های مختلفی برای این کار وجود دارد که با مرور جامع بیش از ۱۵۰ مدل مبتنی بر یادگیری عمیق، روش هایی برای طبقه بندی متن ایجاد شده را که در سال های اخیر ارائه داده اند و در مورد مشارکت های فنی، شباهت ها و نقاط قوت آنها بحث کرده اند. همچنین خلاصه ای بیش از ۴۰ مجموعه داده محبوب را ارائه نموده اند [۱۱]. در پژوهشی به جهت جلوگیری از سخنان توهین آمیز در قسمت نظرات رسانه های اجتماعی، دسته ای از کلماتی را که در مکالمات بین جوانان رایج بوده را با استفاده از کتابخانه NLP پیش پردازش کرده و این مجموعه داده را با استفاده از جاساز (برت و فست تکست) و الگوریتم های یادگیری عمیق (CNN, MLP, LSTM) طبقه بندی کرده است [۱۲]. همچنین پس از بیان این موضوع که طبقه بندی متن، بر اساس الگوریتم های یادگیری

<sup>1</sup> Bert

<sup>2</sup> Hazm

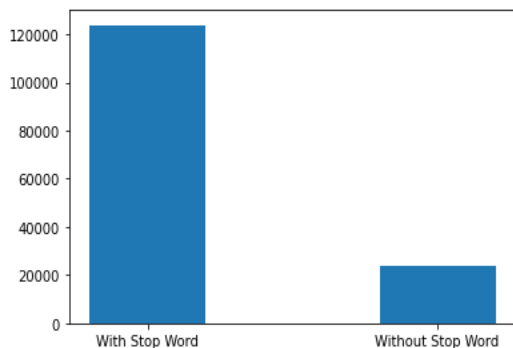
جایگزین کردن کاراکترهای استاندارد در متن ورودی صورت می‌پذیرد.

### ۳-۲-۲- تقطیع جملات و واژه‌ها

این مرحله، تشخیص و استخراج کلمات از متن ورودی است. به عبارت دیگر جداسازی جملات ساده و مرکب (غیرتودرتو) و واژه‌ها و عبارات خاص (توکن‌ها) در این مرحله صورت می‌پذیرد.

### ۳-۲-۳- حذف کلمات توقف

حذف کلمات توقف، حذف علائم، اعداد، کلمات عمومی و بدون ارزش معنایی (از قبیل: از، در، با، به، است، پس، و غیره) می‌بایستی انجام پذیرد. برای انجام این کار در ابتدای کار متن را فراخوانی و نرمال سازی کرده و فاصله‌ها، نیم فاصله‌های اضافی، کلمات ایست واژه را از جملات حذف کرده (کلماتی که دارای محتوای خاصی نیستند و مفهومی را انتقال نمی‌دهند) و پس از آن سایر علامت‌ها و اعداد را از متون حذف می‌کنیم. شکل ۲ مقایسه تعداد کلمات قبل از مرتب سازی متون و بعد آن را نشان می‌دهد. همانطور که در شکل مشاهده می‌شود، تعداد کلمات پس از این کاهش بار پردازشی سیستم خواهد شد.

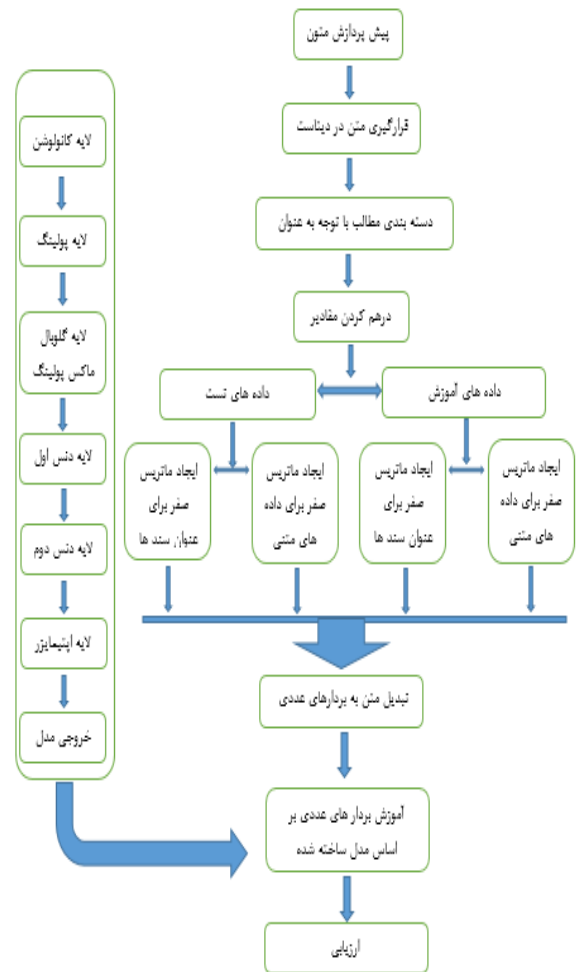


شکل (۲): تعداد کلمات، قبل و بعد مرتب سازی

### ۳-۳- دسته بندی مطالب و قرارگیری متن در

#### مجموعه داده

در این مقاله از یک روش دسته بندی چهار کلاسه استفاده شده است. به این معنا که میزان احتمال یک متن ورودی به یکی از مکاتب سکولاریسم، سوسیالیسم، لیبرالیسم و مارکسیسم مشخص



شکل (۱): فلوچارت مراحل پیشنهادی

### ۳-۲- پیش پردازش متون

متن اولیه را باید به قالبی تبدیل کرد که کلمات دارای معنا استخراج شده، سپس کلمات با معنا برای آموزش به سیستم استفاده گردد. برای نرمال سازی متن، حذف ایست واژه و غیره از کتابخانه ای به نام هضم که بر گرفته از کتابخانه قدرتمند <sup>۱</sup>NLTK می‌باشد استفاده شده است.

### ۳-۲-۱- نرمالسازی متن

در واقع قبل از پردازش متون جهت استانداردسازی حروف و فاصله‌ها بایستی پیش‌پردازش‌هایی روی آنها انجام شود که در این مرحله، تمیز و مرتب کردن متن و یکسان‌سازی کاراکترها با

<sup>۱</sup> Natural language toolkit

کمتری گردآوری می‌کند. توجه به این نکته لازم است که جاسازهای کلمات، متن را به شکل قابل فهم برای انسان تبدیل نمی‌نماید، اما ساختار آماری زبان استفاده شده در نوشتار را نسبتاً درک می‌کنند. هدف آن‌ها نداشت معنایی به فضای هندسی است. این فضای هندسی جاساز نامیده می‌شود. فست تکست با کلمات کمیاب به خوبی کار می‌کند. بنابراین اگر کلمه ای در طول آموزش دیده نشود، می‌توان آن را به ان گرام<sup>۲</sup>هایی تقسیم کرد تا جاسازی شود. کتابخانه فست تکست شامل مدل های ورد تو وک و یک مدل از پیش آموزش دیده است که می‌تواند برای کارهایی مانند طبقه بندی جملات به خوبی استفاده شود. برای شناخت بهتر فست تکست با یک مثال چگونگی طبقه بندی یک جمله شرح داده می‌شود. برای مثال جمله "تصمیم گیری هر شخص بر اساس عقل است"، ابتدا توسط کتابخانه هضم کلماتی فاقد معنا مانند "هر" و "بر" حذف می‌شوند سپس توسط فست تکست به بخش های جداگانه شکست داده می‌شود. (شکل ۳)

توکن های جمله



شکل (۳): بخش بندی جمله توسط فست تکست

کتابخانه فست تکست معنی هر یک از این بخش ها را جستجو خواهد کرد و مجموعه ای از اعداد (که بردار لغت نام دارد) را به هر لغت که در داده آموزشی حداقل یکبار ظاهر شده نسبت می‌دهد. این اعداد، معنی هر لغت را به عنوان یک نقطه در یک فضای ۳۰۰ بعدی، کد نگاری می‌شود.

شکل ۴ نگاهی بر اعداد واقعی از کتابخانه فست تکست که معنی هر کلمه را در جمله ما نمایش می‌دهند.

کلمه	تصمیم	گیری	شخص	اساس	عقل	است
تصمیم	۰.۰۷۳۹۴۰۶۵	۰.۰۳۵۳۳۲۰۷	۰.۰۵۴۸۶۴۹۶	۰.۰۱۹۱۷۹۸۹۲	.....	.....
گیری	-۰.۰۲۶۷۸۲	۰.۰۳۲۸۹۷۷۳	۰.۰۱۳۰۸۲۱۸	-۰.۰۸۵۲۲۴۳۵	.....	.....
شخص	۰.۲۴۹۶۱۹۴۲	۰.۲۶۰۲۱۷۳۷	۰.۱۵۲۷۷۶۶	۰.۰۵۶۲۷۱۲۱	.....	.....
اساس	-۰.۳۶۸۵۶۴۹۶	-۰.۳۵۸۹۹۴۳	۰.۰۸۰۶۳۶۵۳	-۰.۰۹۹۶۳۲۵۴	.....	.....
عقل	۰.۰۴۳۷۰۸۷۴	-۰.۱۵۴۴۵۴۰۸	-۰.۰۳۷۸۳۱۸۶	۰.۰۸۴۲۱۷۹۶	.....	.....
است	۰.۲۶۴۴۸۶۷۶	۰.۰۶۵۱۷۱۳۸	۰.۱۸۶۴۱۰۸۴	۰.۰۶۱۱۷۶۶	.....	.....

شکل (۴): اعدادی که فست تکست به هر کلمه در جمله می‌دهد

می‌شود. پس از قرار گیری داده ها در پایگاه داده، داده ها به دو دسته، داده هایی برای یادگیری و داده هایی برای آزمون دسته بندی می‌شود. بدیهی است در صورت استاندارد نبودن داده های آزمون و آموزش نتیجه ارزیابی به خوبی قابل استناد نباشد. در این مقاله ۸۰ درصد داده ها موجود برای آموزش و بقیه برای آزمون در نظر گرفته شده است. به این ترتیب می‌توان میزان دقت الگوریتم را به دست آورد. برای آنکه داده آزمون، ترکیبی از داده های مختلف از مکاتب مختلف فلسفی باشد، مقادیر را با استفاده از تابع رندم شافل<sup>۱</sup> به صورت تصادفی در آورده، تا داده ها به صورت تصادفی در متغیر پخش شوند و مجموعه داده آزمون ترکیبی از کلاس های مختلف داده ما باشد.

### ۳-۴- تبدیل متن به بردار عددی با کتابخانه فست

#### تکست

روش های مبتنی بر شبکه عصبی به دلیل دقت در زمینه پردازش زبان طبیعی بسیار رایج شده است. با این حال، اکثر این روش ها در تجزیه و تحلیل مجموعه داده های بزرگ زمان بر هستند و برای تجزیه و تحلیل متون نیاز به جاساز کلمه دارند. به همین دلیل، روشی به نام فست تکست پیشنهاد شد [۱۴]. فست تکست کتابخانه ای است سریع، کارآمد و منبع باز که توسط تیم تحقیقاتی فیس بوک برای یادگیری کارآمد در نمایش کلمات و طبقه بندی جملات ایجاد شده است. در فست تکست، مجموعه ای از ترندها برای بهبود سرعت پردازش و عملکرد مدل استفاده شده است که یکی از آنها اسکپ گرام است. اسکپ گرام اجازه می‌دهد برخی از کلمات حذف شوند و کلمات غیرمجاور با هم بررسی شوند [۱۵]. فست تکست روشی برای تبدیل کلمات به بردار عددی است که فرمت آن همانند مدل ورد تو وک است. در کتابخانه فست تکست به جای یادگیری بردارها برای هر کلمه، هر کلمه را به صورت یک گرام از کاراکترها نشان می‌دهد. این کار برای درک معنای کلمات کوتاه تر کمک می‌کند و به جاسازها اجازه می‌دهد پسوندها و پیشوندها را درک کنند. منظور از جاساز کلمات، این است که کلمات به صورت بردارهای کلمات متراکم ارائه می‌شوند، این به معنای این است که جاسازی کلمات اطلاعات بیشتری را در ابعاد

<sup>2</sup> N-gram

<sup>1</sup> Random shuffle

ماتریسی با مقادیر صفر که برای عنوان داده‌های آموزش ایجاد می‌شود. مطابق رابطه (۳) و مقادیر آنها مقادیر پیش فرضی هستند که با توجه به تعداد عنوان (دسته) داده‌ها آموزش تعیین می‌شوند.

$$\text{train\_size} * 4 \quad (3)$$

ماتریسی با مقادیر صفر که برای عنوان داده‌های آزمون ایجاد می‌شود مطابق رابطه (۴) و مقادیر آنها مقادیر پیش فرضی هستند که با توجه به تعداد عنوان (دسته) داده‌ها آموزش تعیین می‌شوند.

$$\text{test\_size} * 4 \quad (4)$$

پس از ایجاد ماتریس‌های تمام صفر، نوبت به ایجاد بردارهای عددی متون می‌رسد. در این مرحله به ازای هر کلمه‌ی جمله، یک بردار عددی توسط کتابخانه فست تکست ایجاد شده و در ماتریس آموزش یا ماتریس آزمون جای گذاری می‌شود.

### ۳-۵- ساخت مدل شبکه یادگیری عمیق

برای عملکرد بهتر سیستم نیاز به ساخت مدلی داریم که بهترین ویژگی‌های داده‌های ورودی را استخراج و به سیستم آموزش بدهد. در این مقاله از چندین لایه در ساخت مدل استفاده شده است.

#### ۳-۵-۱- لایه شبکه کانولوشن<sup>۱</sup> (شبکه عصبی پیچشی)

شبکه‌های عصبی کانولوشن اخیراً عملکرد قابل ملاحظه‌ای در زمینه عملی برای طبقه بندی جملات به دست آورده اند. با این حال، در این روش باید یک مدل دقیق با پارامترهای همراه، از جمله اندازه ناحیه فیلتر، پارامترهای منظم سازی<sup>۲</sup> و غیره تعیین شود [۱۶]. معماری شبکه‌های پیچشی مشابه با الگوی اتصال نورون‌ها در مغز انسان است و از سازمان‌دهی قشر بصری در مغز الهام گرفته شده است. هر نورون به محرک‌ها تنها در منطقه محدودی از میدان بصری که تحت عنوان میدان تاثیر شناخته شده است پاسخ می‌دهد. یک مجموعه از این میدان‌ها برای پوشش دادن کل ناحیه بصری با یکدیگر هم‌پوشانی دارند. در شکل (۶) معماری شبکه عصبی کانولوشن نشان داده شده است. شبکه کانولوشن معمولاً از بلوک‌های مختلفی تشکیل شده است. لایه‌ها یا بلوک‌های مختلف در شبکه CNN عبارتند از:

- لایه ورودی بلوک زرد

معنی هر لغت توسط ۳۰۰ ارزش، کدگذاری شده است. سپس، فست تکست از ستون‌های عمودی اعداد نمایش دهنده هر لغت میانگین می‌گیرد تا یک نمایش ۳۰۰ عددی از معنای کل جمله که بردار سند نام دارد، به وجود آورد (شکل ۵).

جمله	تصمیم‌گیری	شخص اساس	عقل است
۰.۰۳۰۳۳۱۶۷۳	.....	۰.۰۷۴۹۸۹۸۷۵	۰.۰۳۳۸۷۷۵۰۷
۰.۰۳۹۴۸۵۰۲			

شکل (۵): نمایش ۳۰۰ عددی از معنای کل جمله

نهایتاً این ۳۰۰ ارزشی که جمله را نمایش می‌دهند، به عنوان یک ورودی از عنوان طبقه بندی می‌باشد.

در روش پیشنهادی، ماتریس‌ها طبق رابطه ۱ الی ۴ مشخص می‌شوند. ماتریسی را با مقادیر صفر برای داده‌های آموزش ایجاد می‌شود و داده‌های آموزشی در این ماتریس قرار می‌گیرد. اندازه این ماتریس مطابق رابطه (۱) تعیین می‌شود.

$$\text{train\_size} * \text{max\_no\_tokens} * \text{vector\_size} \quad (1)$$

که در آن  $\text{train\_size}$  برابر تعداد سطرهای داده‌های آموزش،  $\text{max\_no\_token}$  برابر تعداد مجاز کلماتی که می‌تواند در یک جمله باشد و  $\text{vector\_size}$  برابر با تعداد ستون‌های ماتریس است، از آنجایی که مدل فست تکست مورد استفاده برای ۳۰۰ ستون است، در این مقاله  $\text{vector\_size}$  را برابر ۳۰۰ در نظر گرفته می‌شود.

در گام دوم همین روند برای ماتریس آزمون نیز انجام می‌شود. بدین صورت که ماتریسی با مقادیر صفر برای داده‌های آزمون ایجاد و داده‌های آزمون در این ماتریس قرار می‌گیرند. اندازه این ماتریس مطابق رابطه (۲) تعیین می‌شود.

$$\text{test\_size} * \text{max\_no\_tokens} * \text{vector\_size} \quad (2)$$

که در این رابطه  $\text{test\_size}$  برابر با تعداد سطرهای داده‌های آموزش،  $\text{max\_no\_token}$  برابر با تعداد مجاز کلماتی که می‌تواند در یک جمله باشد و  $\text{vector\_size}$  برابر با تعداد ستون‌های ماتریس در نظر گرفته شده است.

<sup>2</sup> Regularization


<sup>1</sup> Conventional Neural Network (CNN)



صورت جعلی اندازه ورودی را افزایش داده تا ماتریس خروجی هم‌اندازه ماتریس ورودی شود.

### ۳-۵-۲ لایه بیشترین مقدار ادغام<sup>۷</sup>

لایه ادغام یکی دیگر از لایه‌های مهم در شبکه عصبی کانولوشن است. هدف لایه ادغام کاهش اندازه مکانی نقشه ویژگی<sup>۶</sup> بدست آمده با استفاده از لایه کانولوشنی است. لایه ادغام پارامتر قابل آموزش ندارد. صرفاً یک نمونه برداری ساده و موثر انجام می‌دهد. رایج‌ترین نمونه ادغام، بیشترین مقدار ادغام و میانگین ادغام<sup>۷</sup> است. نتایج نشان می‌دهد که هیچ یک از این دو مدل برتری خاصی نسبت به مدل دیگر ندارد [۱۹]. مطابق شکل ۷ بیشترین مقدار ادغام شامل یک پنجره از پیش تعریف شده است (مثلاً ۳×۳) که روی تصویر حرکت می‌کند (تصویر را اسکن می‌کند) و در هر پنجره مقدار بالاتر را انتخاب می‌کند و بقیه را دور می‌ریزد. مشابه با لایه کانولوشنی، اندازه فیلتر، لایه گذاری لبه‌ها و مقدار گام<sup>۸</sup> در اینجا هم صدق می‌کند. در ادغام، معمولاً مقدار گام ۲ و اندازه فیلتر ۳ در نظر گرفته می‌شود. برای اینکه سایز ویژگی به ۱/۲ کاهش پیدا کند.



شکل (۷): مثالی از نحوه عملکرد لایه ادغام در شبکه عصبی کانولوشن استفاده از بیشترین مقدار ادغام رایج تر است و عملکرد بهتری را از خود نشان داده است. پس از ادغام باید ماتریس تبدیل به یک بردار شده تا داده‌ها را به صورت ترتیبی به لایه متراکم<sup>۹</sup> داده شود. برای این کار از لایه گلوبال ماکس پول<sup>۱۰</sup> استفاده کرده و ماتریس خود را را به یک بردار تبدیل می‌کنیم.


<sup>7</sup> Average pooling  
<sup>8</sup> Stride  
<sup>9</sup> Dense layer  
<sup>10</sup> GlobalMaxPool1D

لایه کانولوشن بلوک‌های آبی

لایه غیرخطی لوک‌های آبی در شکل (معمولاً تابع غیرخطی را همراه با لایه کانولوشنی یک‌جا نشان می‌دهند)

لایه ادغام<sup>۱</sup> بلوک‌های قرمز

لایه تمام متصل<sup>۲</sup> بلوک‌های سبز



شکل (۶): معماری شبکه عصبی کانولوشن [۱۷]

در اولین مرحله روش پیشنهادی از یک لایه کانولوشن استفاده شده است. علت آن، این است که شبکه عصبی پیچشی به هر یک از اشیا و جنبه‌های موجود در متن میزان اهمیت (وزن‌های قابل یادگیری و بایاس) تخصیص می‌دهد و قادر به متمایزسازی آن‌ها از یکدیگر است. همچنین در این شبکه در مقایسه با دیگر الگوریتم‌های دسته‌بندی به پیش‌پردازش کمتری نیاز است. شبکه عصبی پیچشی، در صورتی که به اندازه کافی آموزش دیده باشد قادر به کسب فراگیری فیلترهای مشخصات است.

تعداد نورون‌هایی که در لایه کانولوشن در نظر می‌گیریم بر اساس آزمون و خطا و با توجه به بالاترین کارایی تعیین می‌کنیم. اندازه پنجره لغزان<sup>۳</sup> را یک ماتریس ۵\*۵ در نظر می‌گیریم. این اندازه می‌تواند باعث بازدهی بهتر مدل گردد. همچنین بین توابع فعال ساز، محاسبات در تابع ReLU ساده و صرفاً یک مقایسه است به همین خاطر محاسبات در بخش تابع غیرخطی با استفاده از ReLU نسبت به سایر توابع غیرخطی مانند سیگموئید با سرعت بیشتری انجام می‌شود [۱۸]. از طرفی فرآیند آموزش با ReLU نسبت به سایر توابع غیرخطی سریع‌تر است. در نتیجه از تابع ReLU استفاده شده است. از آنجایی که استفاده از پنجره لغزان ابعاد ماتریس ورودی ما را کم می‌کند در نتیجه از لایه گذاری لبه‌ها<sup>۴</sup> نیز استفاده شده تا به

<sup>1</sup> Pooling layer  
<sup>2</sup> Fully connected layer  
<sup>3</sup> Sliding window  
<sup>4</sup> Padding  
<sup>5</sup> Max pooling  
<sup>6</sup> Feature map

### ۳-۵-۳- لایه متراکم

با لایه‌ی متراکم تمامی گره‌ها در یک لایه به تمام گره‌ها در لایه بعدی متصل شده و معمولاً هر چه تعداد نورون‌ها در این لایه بیشتر شود صحت مدل نیز بیشتر می‌شود ولی از طرفی دیگر افزایش بیش از حد آن هم منجر به بیش پرازش<sup>۱</sup> می‌شود. تابع فعال ساز استفاده شده در این لایه تابع بیشینه هموار<sup>۲</sup> است، چرا که این تابع برای هریک از دسته‌ها یا عناوین یک عدد بین ۰ و ۱ تولید می‌نماید که با آن می‌توان میزان شباهت مقدار ورودی را با هریک از دسته‌ها بدست آورد.

### ۳-۵-۴- لایه بهینه ساز<sup>۳</sup>

الگوریتم بهینه ساز فرآیند و نرخ یادگیری را کنترل می‌کند. بهینه‌سازها به الگوریتم‌ها یا روش‌هایی اطلاق می‌شود که برای تغییر ویژگی‌های شبکه عصبی از قبیل وزن و نرخ یادگیری به کار برده می‌شوند. این کار، نقش موثری در کاهش زیان دارد. نحوه تغییر وزن‌ها یا نرخ یادگیری شبکه عصبی به ابزارهای بهینه‌سازی مورد استفاده بستگی دارد. راهبردها یا الگوریتم‌های بهینه‌سازی مسئول کاهش زیان هستند و دقیق‌ترین نتایج ممکن را به ارمغان می‌آورند. بهینه ساز آدام<sup>۴</sup> بسیار سریع است و به سرعت همگرایی پیدا می‌کند، همچنین نرخ یادگیری و واریانس بالا را اصلاح می‌کند [۲۰]. در روش پیشنهادی از این بهینه ساز استفاده شده است.

### ۳-۶- آموزش سیستم

در این مرحله، بر اساس مدلی که ساخته شده، داده‌های آموزشی به سیستم آموزش داده می‌شود. داده‌ها دو نوع هستند، نوع اول داده‌های اصلی و نوع دوم لیبل داده‌ها هستند که متناسب به داده‌های اصلی هستند. در این مرحله با توجه به پارامترهایی که وجود دارد، به سیستم آموزش داده می‌شود.

### ۳-۶-۱- ارزیابی مدل

در این مرحله از روش ارزیابی<sup>۵</sup> مطابق رابطه (۵) برای اندازه‌گیری صحت داده مدل استفاده می‌شود.

		Real Label	
		Positive	Negative
Predicted Label	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

شکل (۸): محاسبه میزان صحت داده‌ها

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (5)$$

که در رابطه (۵)، TP بیانگر تعداد عنوان کلاس x است، که سیستم به درستی آن را x تشخیص داده است، FP بیانگر تعداد عنوان های کلاس x است، که سیستم آن را x تشخیص نداده است، TN بیانگر تعداد عنوان های کلاسی به جز x که سیستم به درستی آن را x تشخیص نداده است، FN بیانگر تعداد عنوان های کلاسی به جز x است که سیستم آن را x تشخیص داده است.

### ۳-۷- میزان شباهت متن جدید به هر مکتب

در این مرحله، داده‌ای جدید از نویسنده دریافت شده و کلیه مراحل قبل از قبیل مرتب سازی متن، تبدیل متن به بردار عددی در این مرحله انجام و در نهایت میزان شباهت متن جدید با عنوان های آموزش داده شده به دست می‌آید.

### ۴- نتایج و آزمایشات

در این مقاله شش آزمایش مختلف با پارامترهای متفاوت انجام شد. جدول ۲ آزمایشات صورت گرفته در حالت‌های مختلف را به همراه میزان صحت حاصل شده از هر آزمایش نشان می‌دهد.

جدول ۲: میزان صحت داده در آزمایش های مختلف

شماره آزمایش	میزان صحت	پارامترها
۱	۷۸ درصد	استفاده از دو لایه کانولوشن
۲	۷۸ درصد	استفاده از ۲ لایه متراکم
۳	۷۶ درصد	استفاده از ۴ لایه متراکم
۴	۸۶ درصد	استفاده از تعداد نورون ۹۰۰ و ۴۵۰

<sup>4</sup> Adam


<sup>5</sup> Evaluate

<sup>1</sup> Overfitting

<sup>2</sup> Softmax function

<sup>3</sup> Optimizer



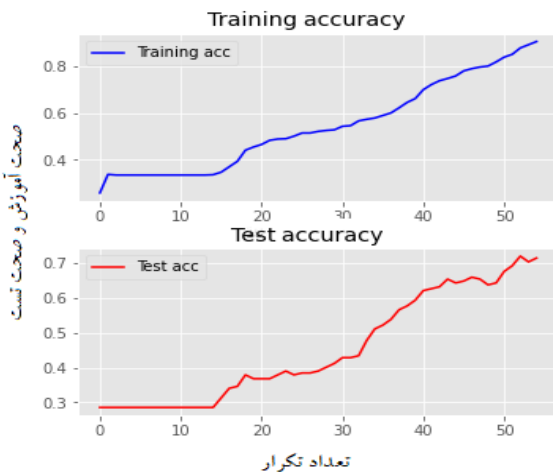


شکل (۹): حداکثر تعداد تکرار

پارامتر اندازه بسته در هر بار تکرار نقش مهمی در یادگیری دارد، اگر مقدار آن زیاد باشد یادگیری ما کم تر و اگر مقدار آن کم باشد بیش پرازش خواهیم داشت. زمانی که اندازه بسته ۵۱۲ در نظر گرفته شد، از تکرار ۳۰ به بعد دچار بیش پرازش شده، و میزان صحت داده ها تا تکرار ۳۰، ۸۳ درصد است و زمانی که اندازه بسته ۲۰۴۸ در نظر گرفته شد، تا تکرار ۵۵ میزان صحت داده ها، ۸۸ درصد است.

مقدار اندازه بسته که در ساخت مدل استفاده شده است برابر ۱۰۲۴ میباشد. (شکل ۱۰)

در مقاله با توجه به موضوع که برای طبقه بندی است برای تابع هزینه<sup>۳</sup> از کراس آنترپی<sup>۴</sup> استفاده شده است.



شکل (۱۰): نمودار خروجی پس از ساخت مدل با روش پیشنهادی

اندازه سایز بسته ۵۱۲	۸۲ درصد	۵
اندازه سایز بسته ۲۰۴۸	۸۸ درصد	۶

از آنجایی که لایه کانولوشن بیشتر در تصاویر پیچیده و چند بعدی استفاده می شود، لذا در پیاده سازی روش پیشنهادی که برای متون است، حالات استفاده از ایجاد یک لایه کانولوشنی و دو لایه کانولوشنی مورد مقایسه قرار گرفته و می توان نتیجه گرفت استفاده بیشتر از یک لایه کانولوشن در متون، باعث کاهش یادگیری می شود.

در روش پیشنهادی تعداد نورون لایه اول متراکم را برابر با ۶۰۰، تعداد نورون لایه دوم را ۳۰۰ و از آنجایی که تعداد دسته بندی ما ۴ است تعداد نورون های لایه سوم ۴ در نظر گرفته شده است. مشخص کردن تعداد نورون ها بر اساس سعی و خطا به دست می آید. در آزمایش بررسی شده مشاهده می شود افزایش تعداد نورون بیشتر از ۶۰۰ باعث بیش پرازش شده، و در نتیجه تعداد نورون ایده آل در روش پیشنهادی برای لایه اول ۶۰۰ و برای لایه دوم ۳۰۰ است.

در روش پیشنهادی بالاترین یادگیری زمانی است که از ۳ لایه متراکم استفاده شده است. در زمان استفاده از ۲ لایه متراکم دقت صحت تا تکرار ۷۸، ۵۵ درصد و زمان استفاده از چهار لایه متراکم دقت صحت تا تکرار ۷۸، ۴۲ درصد می باشد. تکرار بیشتر از ۴۲ منجر به بیش پرازش می شود.

در این مرحله پارامتر هایی از قبیل تعداد دفعات یادگیری<sup>۱</sup> تعیین اندازه اینکه داده ما به در قالب چند تایی به سیستم آموزش داده شود<sup>۲</sup> و تقسیم بندی داده ها با هر بار تکرار، تعیین می شود. پارامتر تعداد دفعات تکرار بر اساس سعی و خطا تعیین می شود و تا زمانی که یادگیری بیشتر و دچار بیش پرازش نشده قابل افزایش است. همینطور که در شکل ۹ قابل مشاهده است از تکرار ۵۵ به بعد ما دچار بیش پرازش شده، پس حداکثر تعداد تکرار ۵۵ در نظر گرفته می شود.

<sup>4</sup> Crossentropy

<sup>1</sup> Epochs


<sup>2</sup> Batch size

<sup>3</sup> Cost function


در نهایت پس از آزمایش‌های متعدد صورت گرفته، پس از ساخت مدل بر اساس جدول ۳، میزان صحت داده‌های آموزش ۹۴ درصد می‌باشد.

جدول (۳): لایه‌های استفاده شده در روش پیشنهادی

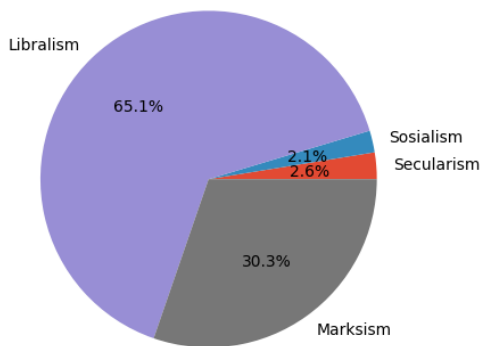
شماره	لایه‌های استفاده شده به ترتیب
۱	یک لایه کانولوشن
۲	یک لایه ادغام
۳	یک لایه گلوبال ماکس پول
۴	۲ لایه متراکم با تعداد نورون ۶۰۰ و ۳۰۰ و تابع فعال‌ساز Relu
۵	۱ لایه متراکم با تعداد نورون ۴ و تابع فعال‌ساز بیشینه هموار
۶	یک لایه بهینه‌ساز آدم



شکل (۱۲): متن "هر شخص باید به اندازه نیازش داشته باشد"



شکل (۱۳): متن "ابزار تولید باید دارای مالکیت دولت باشد"

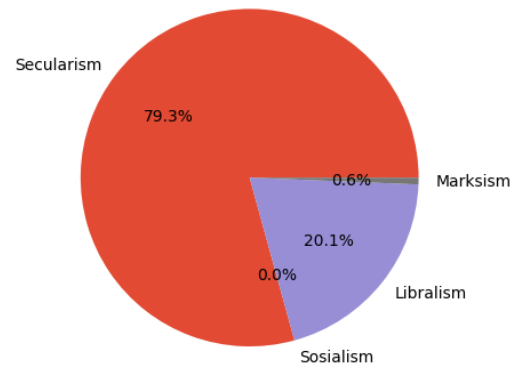


شکل (۱۴): متن "تصمیم‌گیری هر شخص بر اساس عقل است"

بعد از پایان آموزش مثال‌هایی (جدول ۴) از خروجی کار انجام شده که در شکل ۱۱، ۱۲، ۱۳ و ۱۴ قابل مشاهده است.

جدول (۴): مثال‌هایی از متن نویسنده و میزان شباهت با هر مکتب

شماره مثال	متن استفاده شده
۱	جدایی دین از سیاست
۲	هر شخص باید به اندازه نیازش داشته باشد
۳	ابزار تولید باید دارای مالکیت دولت باشد
۴	تصمیم‌گیری هر شخص بر اساس عقل است



شکل (۱۱): متن "جدایی دین از سیاست"

برای تبدیل متن به بردارهای عددی با استفاده از کتابخانه‌های دیگر و مقایسه با روش پیشنهادی خواهد بود.

## References

- [۱] مطهری مرتضی، آشنائی با علوم اسلامی، ج ۱، نشر صدرا، صفحه ۱۴۷.
- [۲] ابونصر فارابی، محمد بن محمد، الجمع بین رأی الحکیمین، صفحه ۲۸.
- [۳] ابن‌سینا، حسین بن عبدالله، الهیات شفا، صفحه ۱۵.
- [4] Deepa Yogish, T. N. Manjunath , Ravindra S. Hegadi. "Review on Natural Language Processing Trends and Techniques Using NLTK": 17 July 2019
- [5] RyanSpring ; MatthewJohnson. "The possibility of improving automated calculation of measures of lexical richness for EFL writing: A comparison of the LCA, NLTK and SpaCy tools": June 2022
- [6] Piotr Semberecki , Henryk Maciejewski , All Authors. "Deep learning methods for subject text classification of articles": 3-6 Sept. 2017
- [7] Mikolov, et al. "Efficient Estimation of Word Representations in Vector Space." ArXiv.org, 7 Sept. 2013
- [8] Tejas Menon. "Empirical Analysis of CBOW and Skip Gram NLP Models" Summer 2020
- [9] Takamune Onishi; Hiromitsu Shiina. "Distributed Representation Computation Using CBOW Model and Skip-gram Model": 1-15 Sept. 2020
- [10] Lucky Agarwal , Kartik Thakral , Gaurav Bhatt , Ankush Mittal. "Authorship Clustering using TF-IDF weighted Word-Embeddings": 12 December 2019
- [11] Shervin Minaee , Nal Kalchbrenner , All Authors. "Deep Learning--based Text Classification: A Comprehensive Review" 17 April 2021
- [12] Pranav Malik; Aditi Aggrawal; Dinesh K. "Toxic Speech Detection using Traditional Machine Learning Models and BERT and fastText Embedding with Deep Neural Networks": April 2021
- [13] Tengjun Yao; Zhengang Zhai. "Text Classification Model Based on fastText": September 2020
- [14] Armand Joulin, Edouard Grave, Piotr Bojanowski, Tomas Mikolov. "Bag of Tricks for Efficient Text Classification" ; [Submitted on 6

## ۵- نتیجه گیری و کارهای آینده

در این مقاله سعی شد تا با استفاده از شبکه‌های عصبی و یادگیری عمیق مکاتب فلسفی متعددی به سیستم آموزش داده شود و عنوان‌هایی را به داده‌ها اختصاص داده، همچنین با دادن داده جدید به سیستم، بتوان عنوان آن داده را مشخص کرد.

مرتب سازی متون قبل از عملیات یادگیری عمیق امری بسیار ضروری و مهم است، چرا که تعداد کلمات غیر ضروری بسیار بیشتر از کلمات مورد نیاز هستند و این خود هم از لحاظ افزایش یادگیری، هم از لحاظ سرعت یادگیری و هم از لحاظ مصرف حافظه دارای تاثیر می باشد. برای تبدیل متون به بردارهای عددی، روش‌های متعددی وجود دارد، که در این مقاله از کتابخانه فست تکست استفاده شده است. کتابخانه فست تکست شامل مدل‌های ورد تو وک و یک مدل از پیش آموزش دیده است که می‌تواند برای کارهایی مانند طبقه بندی جملات به خوبی استفاده شود. یکی از موارد قابل توجه دیگر، انتخاب حداکثر تعداد کلمات مجاز در یک جمله است، زیرا در اندازه ماتریس و در نتیجه در سرعت و مصرف حافظه تاثیر گذار است. در روش پیشنهادی از یک لایه پیچشی استفاده شده است، زیرا استفاده بیشتر در موضوعات متنی باعث کاهش یادگیری می‌شود. برای استفاده از تابع فعال ساز، از تابع بیشینه هموار استفاده شده است. زیرا این تابع برای هر یک از دسته‌ها یا عناوین یک عدد بین ۰ و ۱ می‌دهد که با آن می‌توان میزان شباهت مقدار ورودی را با هر یک از دسته‌ها یا عناوین مشاهده نمود. تابع زیان در روش پیشنهادی را با توجه به اینکه موضوع یک پروژه دسته بندی چند کلاسه است از طبقه بندی کراس آنروپی به عنوان پارامتر برای تابع زیان استفاده شده است. انتخاب مقدار اندازه بسته‌ها مهم می‌باشد، زیرا زیاد یا کم بودن آن کارایی یادگیری عمیق را پایین می‌آورد.

از جمله موضوعاتی که می‌توان در آینده مورد بحث و بررسی قرار بگیرد، امکان استفاده از تعداد عنوان‌های بیشتر مکاتب فلسفی و همچنین استفاده از مطالب با حجم‌های گسترده تر که در افزایش یادگیری بسیار موثر خواهد بود. می‌توان ساخت مدل با لایه‌های متفاوت برای پیاده سازی موضوعات مشابه و همچنین مقایسه با روش پیشنهادی انجام داد. همچنین اجرای روش‌های متفاوت



- Ultrasonic Tomography and Convolutional Neural Networks”; [27 March 2020]
- [18] Dabal Pedomonti. “Comparison of non-linear activation functions for deep neural networks on MNIST classification task” ; [8 Apr 2018]
- [19] Florentin Bieder, Robin Sandkühler, Philippe C. Cattin. “Comparison of Methods Generalizing Max- and Average-Pooling” ; 2 Mar 2021
- [20] Diederik , P. Kingma,, Jimmy Ba. “Adam: A Method for Stochastic Optimization” ; [Submitted on 22 Dec 2014 (v1), last revised 30 Jan 2017 (this version, v9)]
- Jul 2016 (v1), last revised 9 Aug 2016 (this version, v3)]
- [15] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean. “Efficient Estimation of Word Representations in Vector Space” ; [Submitted on 16 Jan 2013 (v1), last revised 7 Sep 2013 (this version, v3)]
- [16] Ye Zhang, Byron Wallace. “A Sensitivity Analysis of (and Practitioners' Guide to) Convolutional Neural Networks for Sentence Classification” ; [Submitted on 13 Oct 2015 (v1), last revised 6 Apr 2016 (this version, v4)]
- [17] Marek Słoński, Krzysztof Schabowicz, Ewa Krawczyk “Detection of Flaws in Concrete Using

## Identifying schools from authors' texts using data mining

Ahmad Alimohamadi<sup>1</sup>, Mohamadmahdi Hoseini<sup>2\*</sup>

<sup>1</sup>Computer Engineering Department, Shahrood Branch, Islamic Azad University, Shahrood, Iran

<sup>2</sup>Computer Engineering Department, Shahrood Branch, Islamic Azad University, Shahrood, Iran

### Article Information

#### Original Research Paper

#### Received:

2023 June 25

#### Accepted:

2023 November 21

#### Keywords:

Philosophical schools, data mining of text, recognition of schools, conversion of text into a numerical vector, degree of similarity of author's thinking with schools

#### Corresponding Author\*:

hosseini\_mm@yahoo.com

### Abstract

In the field of knowledge of philosophical schools, each person's thinking is different according to the type of attitude he can have regarding different schools. Recognizing the author's attitude and its similarity to each of the philosophical schools has always been one of the important issues in the field of humanities. In this article, a method based on deep learning is proposed to distinguish philosophical schools from text. In the proposed method, first the texts are normalized and redundant and meaningless words are removed. After the normalization stage, the text is broken into sentences and words, and then using the fasttext library, each word is converted into a numerical vector, after that, the features of the texts are extracted using the designed network, and finally, the system has learned and is ready to extract data, and by giving a new sentence, its similarity to each school is expressed. Based on the evaluation, the accuracy of the proposed method is 94%.

 : 10.22034/ABMIR.2023.20250.1029

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2023.20250.1029) /© 2023. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

