Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
Volume 13, Number 4, Winter 2025, pp. 26-37
Received: 09/19/2024, Revised: 02/21/2025, Accepted: 02/24/2025

Improving the Accuracy of Quality-Based Web Service Classification by Enhancing Features Through Feature Engineering

Mehdi Nozad Bonab[1], Jafar Tanha[2*] and Mohammad Masdari[3]

1- Department of Computer Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran.
2*- Electrical and Computer Engineering Department, University of Tabriz, Tabriz, Iran.
3- Department of Computer Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran.
[1]mehdinozad@iau.ac.ir, [2*]tanha@tabrizu.ac.ir,and [3]m.masdari@iaurmia.ac.ir

Corresponding author's address: Jafar Tanha, Electrical and Computer Engineering Department, University of Tabriz, 29 Bahman Boulevard, Tabriz, Iran.

Abstract- Web services, which facilitate machine-to-machine communication over the Internet, require accurate classification for reliable and efficient service delivery. The classification significantly affects service discovery, recommendation systems, and service composition. Web service brokers assist users in selecting the most suitable service based on quality parameters. Currently, only a limited number of datasets focusing on web service quality are available. The QWS dataset, with nine quality features for services, is one of the most prominent datasets in this field. However, this dataset overlooks non-functional attributes such as Security, Interoperability, Scalability, and Robustness, which are essential for discovering web services. This paper proposes enhancing the QWS dataset by using feature engineering to create new features from existing ones. The experimental results on the SSL-WSC algorithm demonstrate that the proposed approach significantly improves the classification of web services. This is evidenced by the 5.05% increase in F1-Score, 5.69% increase in accuracy, and 6.92% increase in precision evaluation criteria.

Keywords- Web services, Classification, Quality, Feature Engineering, Feature Enhancement, Machine Learning.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
جلد ۱۳، شماره ۴، زمستان ۱۴۰۳ ، صفحه ۲۶-۳۷
دریافت: ۱۴۰۳/۰۶/۲۹، بازنگری: ۱۴۰۳/۱۲/۰۳، پذیرش: ۱۴۰۳/۱۲/۰۶

افزایش دقت دسته بندی سرویس‌های وب مبتنی بر کیفیت از طریق بهبود ویژگی‌های مجموعه داده

مهدی نوزاد بناب[۱]، جعفر تنها*[۲]، محمد مصدری[۳]
۱- گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران
*۲- دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران.
۳- گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران
[1]mehdinozad@iau.ac.ir, [2]*tanha@tabrizu.ac.ir, [3]m.masdari@iaurmia.ac.ir

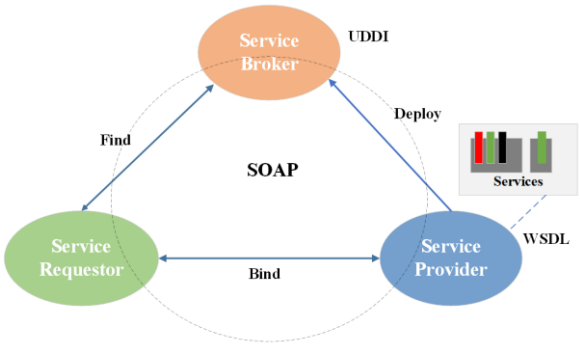
* نشانی نویسنده مسئول: جعفر تنها، تبریز، بلوار ۲۹بهمن، دانشگاه تبریز، دانشکده مهندسی برق و کامپیوتر.

چکیده- سرویس‌های وب سیستم‌های نرم افزاری هستند که برای پشتیبانی از ارتباطات ماشین به ماشین قابل اجرا بر روی اینترنت طراحی شده اند. دسته بندی این سرویس‌ها برای اطمینان از ارائه خدمات قابل اعتماد و کارآمد به کاربران امری ضروری است و نقش مهمی‌در حوزه‌های مختلف مانند کشف سرویس، سیستم‌های توصیه و ترکیب سرویس ایفا می‌کند. کارگزاران سرویس‌های وب با توجه به رتبه بندی سرویس‌ها برپایه پارامتر کیفیت، کاربران را در انتخاب سرویس مناسب از بین سرویس‌های مشابه کمک می‌کنند. در رابطه با سرویس‌های وب، تعداد کمی‌از مجموعه داده‌ها مبتنی برکیفیت سرویس‌های وب در دسترس است. مجموعه داده QWS با نُه ویژگی کیفی برای سرویس‌ها یکی از معروفترین مجموعه داده‌ها در این زمینه است. با این حال، این مجموعه داده برخی از ویژگی‌های غیرعملکردی مانند امنیت، قابلیت همکاری،مقیاس پذیری و استحکام را که در هنگام کشف سرویس‌های وب ممکن است ماهیت حساسی داشته باشند، نادیده گرفته است. در این مقاله، روشی برای بهبود مجموعه داده QWS با استفاده از مهندسی ویژگی‌ها ارائه گردیده که ویژگی‌های جدیدی را برپایه‌ی ویژگی‌های موجود تولید می‌نماید. نتایج آزمایش‌ها بر روی الگوریتم نیمه نظارتی SSL-WSC نشان می‌دهد که رویکرد پیشنهادی در بهبود دسته بندی سرویس‌های وب نتیجه بخش بوده است، بطوریکه مقادیر معیارهای ارزیابی F1-Score، صحت و دقت به ترتیب ۵.۰۵٪، ۵.۶۹٪ و ۶.۹۲٪ افزایش یافته است.

واژه‌های کلیدی: سرویس‌های وب، دسته بندی، کیفیت، مهندسی ویژگی، افزایش ویژگی، یادگیری ماشین.

۱- مقدمه

سرویس‌های وب به طور فزاینده ای برای ایجاد قابلیت همکاری و ارتباط بین سیستم‌ها و برنامه‌های مختلف مورد استفاده قرار می‌گیرند[۱]. کارگزاران وب[۱] به عنوان واسط بین کاربران و سرویس دهندگان نقش مهمی در ارائه و مدیریت سرویس‌های وب ایفا می‌کنند. آنها با جمع آوری و ادغام نیازهای کاربران، باعث کاهش هزینه‌های استفاده از سرویس‌های وب شده و پیچیدگی دسترسی به سرویس‌ها را برای کاربران کاهش می‌دهند. همچنین امکان جست‌وجو، مقایسه و انتخاب سرویس مناسب را نیز فراهم می‌سازند (شکل ۱) [۲]. علاوه بر این، کارگزاران وب می‌توانند منابع مورد نیاز برای مصرف سرویس‌ها را مدیریت نموده و آنها را تخصیص دهند و با اعمال معیارهای کیفی، بر تحویل سرویسِ با کیفیت مناسب نظارت کنند. همچنین کارگزاران سرویس‌های وب نقش مهمی در تضمین امنیت و محافظت از حریم خصوصی تعاملاتِ بین کاربران و سرویس‌های وب ایفا می‌کنند.



شکل۱: معماری سرویس‌های وب

سرویس‌های وب دارای سه موجودیت اصلی هستند: پروتکل دسترسی به اشیای ساده[۲] (اِس او اِی پی)، توصیف جهانی، کشف و یکپارچه سازی[۳] (یو دی دی آی) و زبان شرح سرویس‌های وب[۴] (دبلیو اِس دی اِل) [۳]. اِس او اِی پی یک پروتکل سبک وزن مبتنی بر اِکس اِم اِل[۵] برای تبادل اطلاعات در یک محیط غیرمتمرکز و توزیع شده است[۴]. این پروتکل مستقل از پلتفرم و زبان است. استفاده از اِس او اِی پی از طریق اِچ تی تی پی[۶] امکان برقراری ارتباط آسان‌تر را از طریق پراکسی‌ها و فایروال‌ها نسبت به فناوری اجرای از راه دور قدیمی فراهم می‌کند. یو دی دی آی یک چهارچوب کاری مستقل از پلتفرم و سیستم عامل برای توصیف سرویس‌های وب، جستجوی آنها و ارتباط سرویس‌های وب و تعامل آنها با هم بر روی اینترنت است. از اینرو به عنوان یک رجیستری قوی، انتشار مشخصات سرویس را تسهیل نموده و به‌صورت یک سیستم دایرکتوری ساخت‌یافته عمل می‌کند [۵]. نهایتا دبلیو اِس دی اِل یک زبان مبتنی بر اِکس اِم اِل است که مکانیسمی فراهم می‌کند که از طریق آن تعاریف سرویس‌های وب در معرض دید جهانیان قرار می‌گیرد و استانداردهای تزلزل ناپذیری را تعیین می‌کند که فراهم‌کنندگان سرویس‌های وب باید هنگام ارسال پیام‌های اِس او اِی پی به آن پایبند باشند.

دسته بندی سرویس‌های وب یک وظیفه اساسی در محاسبات سرویس گرا است که بر اساس ویژگی‌های سرویس‌ها به کشف و استفاده کارآمد از سرویس‌های وب کمک می‌کند[۶]. یک سیستم رتبه بندی، ارزش نسبی سرویس‌های مختلف را بر پایه کیفیت سرویس مورد نیاز مشتری و خصوصیات سرویس‌های موجود محاسبه کرده و پس از مقایسه با سرویس‌های دیگر، سرویس مناسب را به کاربر پیشنهاد می‌کند. با توجه به افزایش روز افزون ارائه‌دهندگان سرویس وب در سال‌های اخیر، تعداد سرویس‌های وبی که عملکرد یکسانی دارند نیز افزایش یافته است. تفاوت این سرویس‌های وب مشابه، تنها در کیفیت عملکردشان می باشد. مولفه کیفیت سرویس در زمینه سرویس‌های وب شامل یک سری ویژگی‌های غیرعملیاتی مانند هزینه و زمان اجرا، در دسترس بودن، میزان موفقیت اجرا، امنیت و غیره است. در رابطه با سرویس‌های وب، تعداد معدودی مجموعه داده مبتنی برکیفیت سرویس‌های وب در دسترس است. علت آن این است که سرویس‌ها باید کشف شوند و رفتار کیفی آنها در طول زمان برای محاسبه مقادیر ویژگی‌های غیر عملکردی مشاهده شود. از این رو تولید مجموعه داده مبتنی بر کیو او اِس[۷] از سرویس‌های وب یک کار دشوار، گران و زمان بر بوده و جمع آوری اطلاعات سرویس‌ها از منابع مختلف و تولید ساختار مجموعه داده نیاز به تلاش انسانی بیشتری دارد [۷].

مجموعه داده QWS یک مجموعه داده است که شامل پارامترهای کیفی برای سرویس‌های وب است[۸]. این مجموعه داده پایه‌ای برای درک و دسته بندی سرویس‌های وب فراهم می‌کند. در این مجموعه داده، اطلاعات کیفی تعداد ۲۸۷۱ سرویس وب جمع آوری شده است. از این تعداد، ۳۶۴ سرویس وب دارای برچسب هستند که به طور سیستماتیک در چهار کلاس دسته بندی شده اند. برچسب‌ها سطح کیفی هر سرویس را نشان می‌دهند. همچنین ۲۵۰۷ داده بدون برچسب نیز در این مجموعه داده موجود است. اطلاعات کیفی هر کدام از سرویس‌ها شامل نه ویژگی است. با اینحال در این مجموعه داده برخی از ویژگی‌های غیرعملکردی بسیار مهم مانند امنیت، قابلیت همکاری، مقیاس پذیری و استحکام که در هنگام کشف سرویس‌های وب ماهیت حساسی دارند، نادیده گرفته شده است. این ویژگی‌ها، کلاس سرویس‌هائی را تشکیل می‌دهند که می‌توانند برای کاربردهای دفاعی مرتبط با امنیت ملی و سرویس‌های مربوط به تراکنش‌های مالی سنگین مورد استفاده قرار گیرند.

امروزه یکی از تکنولوژی‌هایی که برای یادگیری از داده و پیدا کردن ساختار مخفی آن استفاده می‌شود فیلدی به نام یادگیری ماشین و داده‌کاوی است[۹, ۱۰]. از آنجائیکه سناریوی تعریف شده برای انتخاب بهترین سرویس از طریق تحلیل و پیشنهاد از طرف سیستم می‌باشد، بنابراین استفاده از تکنولوژی‌های داده‌کاوی و یادگیری ماشین برای یادگیری و ارائه سیستم اتوماتیک در این حوزه ضروری است[۱۱]. دریافت اطلاعات دقیق در مورد سرویس‌ها شامل جمع آوری داده‌ها از چندین ارائه دهنده سرویس است. روش‌ها و رویکردهای مختلفی برای داده کاوی وجود دارد که هر کدام برای کاربرد خاصی مناسب است که می‌تواند انواع خاصی از دانش را استخراج کند. با توجه به اینکه در دیتاست موجود بخش کوچکی از داده‌ها دارای برچسب و بخش بزرگی بدون برچسب می‌باشند، ما در کار قبلی خود با استفاده از رویکرد یادگیری نیمه نظارتی[۱۲]، الگوریتم SSL-WSC را ارائه داده‌ایم که با استفاده از یک روش دو

مرحله‌ای اقدام به برچسب گذاری داده‌های بدون برچسبِ مجموعه داده QWS می‌کند و این الگوریتم باعث بهبود عملکرد سه معیار ارزیابی دقت[۸]، صحت[۹] و F1-Score در دسته بندی سرویس‌ها گردیده است [۷].

در چشم انداز به سرعت در حال تحول فناوری دیجیتال، توانایی دسته بندی کارآمد سرویس‌های وب برای افزایش تجربه کاربر و تضمین ارائه سرویس‌های با کیفیت بالا بسیار پراهمیت شده است. در قلب این تلاش، مهندسی ویژگی‌ها قرار دارد، یک جزء حیاتی که با معرفی ویژگی‌های جدید یا اصلاح ویژگی‌های موجود، عملکرد مدل‌های یادگیری ماشین را به طور قابل توجهی بهبود می‌بخشد. این فرآیند برای استفاده از پتانسیل‌های گسترده یادگیری ماشین در دسته بندی، سازماندهی و بهینه سازی سرویس‌های وب حیاتی است و در نهایت منجر به بهبود کیفیت سرویس‌ها و رضایت کاربر می‌شود. در زمینه دسته بندی سرویس‌های وب، الگوریتم‌های مختلفی ارائه گردیده است. هدف ما در این مقاله بهبود کارائی الگوریتم‌های موجود از طریق تقویت مجموعه داده QWS است. این کار با افزودن ویژگی‌های اضافی از طریق مهندسی ویژگی صورت می‌گیرد که با برچسب گذاری دقیق‌تر سرویس‌های بدون برچسب، دقت دسته بندی را افزایش می‌دهد. ما نام این دیتاست جدید را QWS توسعه یافته (EQWS) قرار داده ایم. دستاوردهای اصلی این مقاله به شرح زیر است:

- بهبود نتایج حاصل از الگوریتم نیمه نظارتی SSL-WSC در راستای دسته بندی و دسترسی بهتر به سرویس‌های وب مبتنی بر کیفیت مورد نیاز کاربر.
- ارائه فرمولهای تجربی برای ایجاد ویژگی‌های جدید با استفاده از مهندسی ویژگی برای مجموعه داه QWS و تولید مجموعه داده جدید EQWS.
- ایجاد تعادل بین درخواست‌های کاربران و ارائه سرویس‌های مطلوب برای آنها.
- کاهش هزینه‌های منابع انسانی برای جمع آوری اطلاعات بیشتر مربوط به سرویس‌های وب.
- افزایش دقت دسته بندی سرویس‌های وب.
- ارائه ایده برای کارهای آینده جهت بهبود دسته‌بندی سرویس‌های وب.

بخش‌های بعدی مقاله به صورت زیر سازماندهی شده است: بخش دوم کارهای مرتبط را بررسی می‌کند. بخش سوم QWS توسعه یافته را بیان می‌کند. بخش چهارم جزئیات آزمایش‌ها و نتایج را ارائه می‌دهد. در نهایت، بخش پنجم شامل نتیجه گیری و پیشنهادها برای کارهای آینده است.

۲- کارهای مرتبط

برای افزایش تعداد ویژگی‌های مجموعه داده‌های مربوط به سرویس‌های وب، می‌توان روش‌های مختلفی مانند مهندسی ویژگی، استخراج ویژگی و انتخاب ویژگی را بررسی نمود.

مهندسی ویژگی، شامل ایجاد ویژگی‌های جدید از مجموعه ویژگی‌های موجود است. این را می‌توان با تبدیل ویژگی‌های موجود یا ترکیب آنها به روشی جدید انجام داد. به عنوان مثال، اگر مجموعه داده شامل یک ویژگی برای تاریخ سرویس باشد، می‌توان از مهندسی ویژگی برای ایجاد ویژگی‌های جدید مانند روز هفته یا زمان روز استفاده کرد. مهندسی ویژگی برای شناسایی ویژگی‌های جدیدی که ممکن است برای تجزیه و تحلیل مفید باشد، به تخصص و خلاقیت حوزه نیاز دارد[۱۳].

استخراج ویژگی، شامل تبدیل ویژگی‌های موجود به مجموعه جدیدی از ویژگی‌ها است. این را می‌توان با استفاده از تکنیک‌هایی مانند تجزیه و تحلیل مؤلفه اصلی[۱۰] یا تجزیه ارزش منفرد[۱۱] انجام داد. این تکنیک‌ها می‌توانند به کاهش ابعاد مجموعه داده کمک کنند و در عین‌حال اطلاعات مهم را حفظ کنند. استخراج ویژگی زمانی مفید است که تعداد زیادی ویژگی در مجموعه داده موجود باشد و هدف ساده سازی تحلیل باشد[۱۴].

انتخاب ویژگی، شامل انتخاب مرتبط ترین ویژگی‌ها از مجموعه ویژگی‌های موجود است. این کار را می‌توان با استفاده از تکنیک‌هایی مانند تحلیل همبستگی[۱۲] یا اطلاعات متقابل[۱۳] انجام داد. انتخاب ویژگی به کاهش ابعاد مجموعه داده کمک می‌کند، که می‌تواند عملکرد مدل‌های یادگیری ماشینی را بهبود بخشد و بیش از حد برازش[۱۴] را کاهش دهد[۱۵].

نرگسیان و همکاران در [۱۳] به موضوع مهندسی ویژگی برای مسائل دسته بندی در یادگیری ماشین پرداختند. آنها ضمن تشریح اهمیت و چالش‌های مهندسی ویژگی، راهکارهای عملی متنوعی را برای طراحی، انتخاب و ترکیب ویژگی‌های موثر ارائه دادند. موارد مطرح شده شامل بررسی همبستگی ویژگی‌ها، استفاده از روش‌های انتخاب ویژگی پیشرفته، ایجاد ویژگی‌های جدید از ترکیب ویژگی‌های موجود، تحلیل معنای فیزیکی ویژگی‌ها، و ارزیابی مدل با ویژگی‌های طراحی شده می‌باشد. رودریگوئز و همکاران در [۱۶] یک روش جدید برای استخراج ویژگی از سرویس‌های وب ارائه داده اند که بر تحلیل متن و ساختار دابلیو اِس دی اِل آن‌ها متمرکز

است. هدف اصلی این روش، شناسایی ویژگی‌های مهم برای دسته‌بندی و کشف سرویس‌های وب می‌باشد. نتایج نشان می‌دهد که استفاده از ویژگی‌های استخراج شده توسط این روش، منجر به بهبود عملکرد دسته‌بندی سرویس‌های وب نسبت به سایر رویکردهای استخراج ویژگی می‌شود. همچنین این روش از پیچیدگی محاسباتی پایینی برخوردار است که آن را برای کاربردهای عملی مناسب می‌سازد. محدودیت‌های این روش شامل تمرکز بر ویژگی‌های متنی و ساختاری دابلیو اِس دی اِل، عدم توجه به پویاییِ سرویس‌های وب، عدم ارزیابی در محیط‌های واقعی و مقایسه محدود با سایر روش‌های پیشرفته استخراج ویژگی است.

جیمز مکس کانتر و همکاران در مقاله [۱۷] یک روش جدید مبتنی بر فیلترینگ مشارکتی[۱۵] برای انتخاب ویژگی‌های مهم در سرویس‌های وب لحاظ کردند. هدف اصلی این روش بهبود عملکرد دسته‌بندی و کشف سرویس‌های وب می‌باشد. روش پیشنهادی قادر است با استفاده از تجزیه و تحلیل تعاملات بین ویژگی‌ها و سرویس‌های وب، ویژگی‌های مؤثر را شناسایی کند. در [۱۸] سریواستاوا و همکاران تکنیکی به نام Dropout را معرفی کردند که برای جلوگیری از پدیده بیش از حد برازش در شبکه‌های عصبی استفاده می‌شود. بیش از حد برازش به این معنی است که شبکه عصبی به طور بیش از حد به داده‌های آموزشی خود وابسته شده و در نتیجه عملکرد ضعیفی در داده‌های جدید و ناآشنا خواهد داشت. در این روش، در طول فرآیند آموزش شبکه عصبی، برخی از نورون‌ها به طور تصادفی از مدل حذف می‌شوند. این باعث می‌شود که شبکه به طور بیش از حد به داده‌های خاص آموزشی خود وابسته نشود و در نتیجه، عملکرد بهتری در داده‌های جدید خواهد داشت. این تکنیک ساده و موثر می‌تواند به طور مستقیم در بهبود عملکرد مدل‌های یادگیری ماشین استفاده شده و بر روند انتخاب ویژگی‌های مناسب نیز تأثیرگذار باشد.

چیا و همکاران در [۱۹] یک رویکرد نوآورانه برای مهندسی ویژگی تطبیقی ارائه داده اند که به بهبود عملکرد سیستم‌های رتبه‌بندی و توصیه‌های معطوف به کاربر منجر می‌شود. این رویکرد با استفاده از یادگیری عمیق، به طور خودکار ویژگی‌های مؤثر را از داده‌ها استخراج می‌کند. نتایج تجربی مقاله نشان می‌دهد این روش در مقایسه با روش‌های موجود عملکرد بهتری دارد. با این‌حال این روش تنها به بررسی کاربرد این رویکرد در مسائل رتبه‌بندی و توصیه‌ای محدود شده است، در حالی که می‌توان آن را در سایر زمینه‌های یادگیری ماشین نیز بررسی کرد.

به هر حال روش‌های مطرح شده برای ایجاد ویژگی‌های جدید، هر کدام دارای مزایا و معایب خاص خود می‌باشند و انتخاب روش به نوع داده‌ها و هدف نهایی تحلیل بستگی دارد. برای ایجاد ویژگی‌های جدید قابلیت همکاری، امنیت، مقیاس‌پذیری و استحکام از ویژگی‌های موجود در مجموعه داده QWS، می‌توان از تکنیک‌های مهندسی ویژگی استفاده نمود.

۳- QWS توسعه یافته

در این بخش مجموعه داده QWS به تفصیل معرفی شده و در ادامه ویژگی‌های جدیدی که این مقاله جهت افزودن به این مجموعه داده مدنظر قرار داده است از جنبه‌های مختلف مورد بررسی قرار گرفته است. همچنین فرمولهائی برای بدست آوردن مقادیر هر کدام از این ویژگی‌های جدید ارائه شده است.

۳-۱- مجموعه داده QWS

کشف سرویس‌ها و مشاهده رفتار کیو او اِس آنها در طول زمان برای محاسبه مقادیر ویژگی‌های غیرعملکردی آنها جهت ایجاد مجموعه داده ای با کیفیت امری چالش برانگیز است. از این رو در واقعیت، تنها چند مجموعه داده برای سرویس‌های وب بر اساس کیفیت آنها در دسترس است.

این مقاله از مجموعه داده QWS که حاوی اطلاعاتی در مورد ۲۸۷۱ سرویس وب واقعی است، استفاده می‌کند. این مجموعه داده به طور سیستماتیک ۳۶۴ سرویس وب دارای برچسب را در چهار کلاس دسته بندی می‌کند. برچسب‌ها سطح کیفی هر سرویس را نشان می‌دهند. علاوه بر این، مجموعه داده شامل ۲۵۰۷ داده بدون برچسب است. مجموعه داده QWS مجموعه ای از ۹ ویژگی کیفی است که برای ارزیابی سرویس‌های وب استفاده می‌شود. ویژگی‌های موجود در مجموعه داده عبارتند از: زمان پاسخگویی، در دسترس بودن، توان عملیاتی، توانایی موفقیت، قابلیت اطمینان، انطباق، بهترین عملکرد، تأخیر و مستندات. این ویژگی‌ها برای اطمینان از کیفیت بالای سرویس‌های وب و ارائه نتایج مورد انتظار به کاربران ضروری هستند. همچنین، داده‌های برچسب‌گذاری‌شده مجهز به ویژگی دسته‌بندی سرویس‌ها است که به هر داده مقداری از یک تا چهار را به عنوان برچسب آن اختصاص می‌دهد (۱: پلاتین، ۲: طلا، ۳: نقره، و ۴: برنز). شکل۲ یک نمای کلی مختصر از فیلدهای مجموعه داده QWS ارائه می‌دهد که در آن نُه کادر اول ویژگی‌های مجموعه داده را نشان می‌دهد و چهار کادر آخر اطلاعات تکمیلی را ارائه می‌دهد.



شکل۲- فیلدهای مجموعه داده QWS

۳-۲- QWS با ویژگی‌های جدید

در این مقاله برای غنی‌سازی مجموعه داده، ویژگی‌های جدیدی را با فرمول‌بندی روابط بین ویژگی‌های موجود و کلاس‌های هدف معرفی می‌کنیم که به‌طور بالقوه منجر به بهبود دقت دسته‌بندی می‌شوند. ویژگی‌های جدید عبارتند از تعامل پذیری، امنیت، قابلیت مقیاس پذیری و استحکام که ذاتا پارامترهای حساسی هستند و با استفاده از فرمول‌های خاص از ویژگی‌های موجود استخراج می‌کنیم. از این رو استفاده از تولید ویژگی‌های جدید منجر به ایجاد مجموعه داده جدید EQWS می‌شود که باعث دسترسی به کلاسی از سرویس‌ها برای استفاده در برنامه‌های دفاعی مربوط به امنیت ملی، معاملات مالی سنگین و ... می‌شود.

الف- تعامل پذیری (قابلیت همکاری)

تعامل پذیری به توانایی سرویس‌های وب برای همکاری با یکدیگر اشاره دارد. این ویژگی می‌تواند سازگاری سرویس‌های وب با سایر سرویس‌های سیستم را اندازه گیری کند. همچنین این ویژگی دقت دسته بندی را با ثبت سازگاری سرویس و سهولت ادغام با نهادهای خارجی افزایش می‌دهد. برای مثال، می‌توان درصد درخواست‌هایی را محاسبه کرد که توسط سایر سرویس‌های وب در سیستم با موفقیت پردازش می‌شوند. برای استخراج ویژگی جدید تعامل پذیری از مجموعه داده‌های QWS، می‌توان از ترکیبی از ویژگی‌های موجود با روابط خاصی استفاده نمود. در جدول ۱ چند پیشنهاد در مورد اینکه چگونه می‌توان ویژگی تعامل پذیری را از ویژگی‌های موجود در مجموعه داده QWS استخراج نمود آورده شده است.

با تجزیه و تحلیل این روابط و کاوش اتصالات بالقوه در مجموعه داده، در این مقاله ما از مقادیر سه ویژگی انطباق، مستندسازی و در دسترس بودن برای ایجاد مقادیر ویژگی تعامل پذیری استفاده نموده‌ایم (فرمول ۱) [۲۰].

$$Interoperability = \sqrt{\frac{(Availability + Compliance + Documentation)}{3}} \quad (۱)$$

ب- امنیت

امنیت به محافظت از خدمات وب در برابر دسترسی یا حملات غیرمجاز اشاره دارد. این ویژگی می‌تواند سطح امنیت سرویس‌های وب را اندازه گیری کند. برای مثال، می‌توان درصد درخواست‌هایی را که احراز هویت و رمزگذاری شده‌اند محاسبه نمود. برای استخراج یک ویژگی جدید برای امنیت از مجموعه داده QWS، می‌توان روابط بین ویژگی‌های موجود را در نظر گرفت. در جدول ۲ به‌طور خلاصه

نحوه ارتباط بالقوه ویژگی‌های موجود برای استخراج ویژگی امنیتی جدید آورده شده است.

جدول ۱. تأثیر ارزش ویژگی‌های موجود بر ایجاد ویژگی تعامل پذیری

ویژگی(ها)	تاثیر مقادیر این ویژگی(ها) در ایجاد ویژگی تعامل پذیری
انطباق و مستندسازی	سرویسی که با استانداردها مطابقت داشته و با ارائه دستورالعمل‌های واضح در مورد نحوه تعامل و تبادل مؤثر داده‌ها توسط سیستم‌های مختلف به خوبی مستند شده باشد، می‌تواند قابلیت همکاری را بهبود ببخشد.
قابلیت اطمینان و در دسترس بودن	قابلیت اطمینان بالا و در صورت نیاز در دسترس بودن می‌تواند نشان دهنده قابلیت همکاری بهتر باشد زیرا سیستم‌ها همیشه در دسترس بوده و برای تبادل داده قابلیت اعتماد بالاتری دارند.
زمان پاسخ و تأخیر	این دو ویژگی می‌توانند با قابلیت همکاری همبستگی منفی داشته باشند. زمان پاسخ و تأخیر بالاتر ممکن است نشان دهنده مشکلات بالقوه در ارتباط بین سیستم‌ها باشد.
توان عملیاتی	در سناریوهایی که برای یکپارچه سازی بین سرویس‌ها، نرخ انتقال داده بالا مورد نیاز است توان عملیاتی بالاتر می‌تواند نشان‌دهنده قابلیت همکاری بهتر باشد. زیرا نشان‌دهنده میزان داده‌هایی است که می‌توانند به‌طور موثر بین سیستم‌ها پردازش و منتقل شوند.
موفقیت و بهترین شیوه‌ها	سرویس‌هایی که نرخ موفقیت بالایی داشته و بهترین شیوه‌ها را دنبال می‌کنند، به احتمال زیاد با سیستم‌های دیگر قابلیت همکاری دارند، زیرا برای ارتباطات و تعامل کارآمد طراحی شده‌اند.
انطباق و بهترین شیوه‌ها	پیروی از انطباق و بهترین شیوه‌ها می‌تواند با اطمینان از اینکه سیستم‌ها از استانداردهای صنعت برای تبادل داده پیروی می‌کنند، قابلیت همکاری را افزایش دهد

جدول ۲. تأثیر ارزش ویژگی‌های موجود بر ایجاد ویژگی امنیت

ویژگی(ها)	تاثیر مقادیر این ویژگی(ها) در ایجاد ویژگی امنیت
قابلیت اطمینان و در دسترس بودن	قابلیت اطمینان و در دسترس بودن بالا می‌تواند ارتباط مثبتی با امنیت داشته باشد. سیستم‌های ایمن اغلب قابل اعتماد بوده و به‌طور مداوم برای جلوگیری از دسترسی یا نفوذ غیرمجاز در دسترس هستند.
انطباق و بهترین شیوه‌ها	رعایت استانداردهای انطباق و بهترین شیوه‌ها برای امنیت بسیار مهم است. سیستم‌هایی که از پروتکل‌های امنیتی و استانداردهای صنعتی پیروی می‌کنند، احتمالاً ایمن هستند.
مستندسازی	مستندسازی خوب می‌تواند با ارائه دستورالعمل‌هایی برای اجرای اقدامات امنیتی و حصول اطمینان از اینکه پروتکل‌های امنیتی به‌درستی دنبال می‌شوند، بر امنیت تأثیر مثبت بگذارد.
زمان پاسخ و تأخیر	زمان پاسخ و تأخیرِ کمتر، می‌تواند با امنیت بهتر همراه باشد. زمان پاسخ سریع و تأخیر کم می‌تواند نشان دهنده اقدامات امنیتی کارآمد برای مدیریت ایمن داده‌ها باشد.
توان عملیاتی	توان عملیاتی بالاتر نشان می‌دهد که سیستم‌ها می‌توانند حجم بیشتری از داده‌ها را به‌طور ایمن و کارآمد مدیریت کنند. از این رو ممکن است نشان دهنده امنیت بهتر باشد.
موفقیت	نرخ موفقیت بالا در تبادل داده‌ها می‌تواند به امنیت مربوط باشد، زیرا تراکنش‌های داده موفق اغلب به ارتباط ایمن بین سیستم‌ها دلالت دارد.

با تجزیه و تحلیل این روابط و کاوش اتصالات بالقوه در مجموعه داده، در این مقاله ما از مقادیر دو ویژگی انطباق، و قابلیت اطمینان برای ایجاد مقادیر ویژگی امنیت در سراسر سرویس‌های وب در مجموعه داده QWS استفاده نموده ایم. این ویژگی جدید به ارزیابی و درک جنبه‌های امنیتی سیستم‌ها کمک می‌کند (فرمول۲) [۲۱].

$$Security = 1 - (1 - compliance) \times (1 - Reliability) \qquad (۲)$$

ج- مقیاس پذیری

مقیاس پذیری در زمینه سرویس‌های وب به توانایی سرویس‌های وب برای رسیدگی به تعداد فزاینده درخواست‌ها اشاره دارد. برای استخراج یک ویژگی جدید برای مقیاس‌پذیری از مجموعه داده‌های QWS، می‌توان روابط بین ویژگی‌های موجود را در نظر گرفت. در جدول ۳ نحوه ارتباط بالقوه ویژگی‌های موجود برای استخراج ویژگی مقیاس پذیری جدید آورده شده است. با تجزیه و تحلیل روابط فوق در مجموعه داده، از مقادیر دو ویژگی توان عملیاتی و تاخیر برای ایجاد ویژگی مقیاس پذیری استفاده نموده ایم. این ویژگی جدید به ارزیابی و درک جنبه‌های مقیاس پذیری سرویس‌ها کمک می‌کند (فرمول۳) [۲۲].

$$Scalability = \frac{Throughput}{1 + \sqrt{Latency}} \qquad (۳)$$

جدول۳. تأثیر ارزش ویژگی‌های موجود بر ایجاد ویژگی مقیاس پذیری

ویژگی	تاثیر مقادیر این ویژگی در ایجاد ویژگی مقیاس پذیری
توان عملیاتی	توان عملیاتی بالاتر اغلب با مقیاس پذیری بهتر همراه است. سیستم‌هایی با توان عملیاتی بالاتر می‌توانند حجم بیشتری از داده‌ها یا درخواست‌ها را مدیریت کنند که نشان‌دهنده مقیاس‌پذیری است.
زمان پاسخگویی	زمان پاسخِ کمتر می‌تواند نشان دهنده مقیاس پذیری خوب باشد. سیستم‌هایی که می‌توانند زمان پاسخ‌دهی پایین را حتی با افزایش بار کاری حفظ کنند، احتمالاً مقیاس‌پذیرتر هستند.
در دسترس بودن	در دسترس بودن بالا برای مقیاس پذیری بسیار مهم است. سیستم‌هایی که بسیار در دسترس هستند می‌توانند با افزایش حجم کار، به کار خود ادامه دهند و مقیاس‌پذیری را نشان دهند.
قابلیت اطمینان	سیستم‌های با قابلیت اطمینان بالا اغلب مقیاس‌پذیرتر هستند، زیرا می‌توانند بدون به خطر انداختن عملکرد یا پایداری، با افزایش تقاضاها مقابله کنند.
تأخیر	تأخیر کمتر می‌تواند به مقیاس پذیری بهتر مرتبط باشد. سیستم‌هایی با تأخیر کم می‌توانند درخواست‌ها را حتی با افزایش حجم کار به‌طور مؤثر پردازش کنند و مقیاس‌پذیری را به نمایش بگذارند.
مستندسازی	مستندات خوب می‌توانند با ارائه دستورالعمل‌هایی برای مقیاس‌پذیری مؤثر سیستم در صورت افزایش تقاضا، در مقیاس‌پذیری نقش داشته باشند.

د- استحکام

استحکام به توانایی سرویس‌های وب برای مدیریت موثر خطاها یا خرابی‌ها و موقعیت‌های غیرمنتظره اشاره دارد. این ویژگی می‌تواند سطح استحکام سرویس‌های وب را اندازه گیری کند. برای مثال، می‌توان درصد درخواست‌هایی را محاسبه نمود که با وجود خطاها یا خرابی‌ها با موفقیت پردازش می‌شوند. برای استخراج ویژگی جدید استحکام از مجموعه داده QWS، می‌توان روابط بین ویژگی‌های موجود را در نظر گرفت. در جدول ۴ نحوه ارتباط بالقوه ویژگی‌های موجود برای استخراج ویژگی استحکام جدید آورده شده است.

جدول ۴. تأثیر ارزش ویژگی‌های موجود بر ایجاد ویژگی استحکام

ویژگی(ها)	تاثیر مقادیر این ویژگی(ها) در ایجاد ویژگی استحکام
قابلیت اطمینان و در دسترس بودن	قابلیت اطمینان و در دسترس بودن بالا اغلب نشان دهنده سیستم‌های قوی است. سیستم‌های قوی می‌توانند قابلیت اطمینان و در دسترس بودن خود را حتی زمانی که با چالش‌های غیرمنتظره مواجه می‌شوند حفظ کنند.
انطباق و بهترین شیوه‌ها	پیروی از استانداردهای انطباق و بهترین شیوه‌ها می‌تواند به استحکام سیستم کمک کند. سیستم‌هایی که از استانداردهای صنعتی و بهترین شیوه‌ها پیروی می‌کنند، احتمالاً در مدیریت سناریوهای مختلف قوی‌تر هستند.
زمان پاسخ و تأخیر	سیستم‌هایی با زمان پاسخ و تأخیر کم ممکن است قوی تر در نظر گرفته شوند. زمان پاسخ سریع و تاخیر کم می‌تواند به سیستم کمک کند تا به سرعت از خطاها یا رویدادهای غیرمنتظره بازیابی کند.
مستندسازی	مستندسازی خوب همچنین می‌تواند با ارائه دستورالعمل‌هایی برای مدیریت مؤثر خطاها، استثناها و موقعیت‌های غیرمنتظره، استحکام سیستم را افزایش دهد.
موفقیت	نرخ موفقیت بالا در تبادل داده ممکن است نشان دهنده استحکام باشد. سیستم‌هایی که می‌توانند نرخ موفقیت بالایی را حتی در شرایط چالش برانگیز حفظ کنند، احتمالا قوی‌تر هستند.

با بررسی روابط فوق و کاوش اتصالات بالقوه در مجموعه داده، مقادیر ویژگی جدید استحکام را از ترکیب مقادیر ویژگی‌های قابلیت اعتماد و زمان پاسخ ایجاد نمودیم که این ویژگی جدید به ارزیابی و درک استحکام کمک خواهد کرد (فرمول۴) [۲۰].

$$Robustness = \frac{Reliability}{1 + \sqrt{Response\ Time}} \qquad (۴)$$

با استفاده از فرمولهای ۱تا ۴، چهار ویژگی جدید به مجموعه داده QWS اضافه گردیده و برچسب زنی سرویس‌های بدون برچسب و به طبع آن دسته بندی این سرویس‌ها با استفاده از پیاده سازی الگوریتم SSL-WSC بر روی مجموعه داده جدید EQWS انجام گرفته است.

۴- نتایج آزمایش‌ها

در این بخش تاثیر ویژگی‌های جدید اضافه شده به مجموعه داده QWS را در بهبود کارائی الگوریتم SSL-WSS که اخیرا ارائه داده ایم[۷]، مورد بررسی قرار داده و بهبود مشهود دسته‌بندی سرویس‌های وب مبتنی بر کیفیت را نشان داده ایم. تمامی‌الگوریتم‌ها با استفاده از زبان برنامه نویسی پایتون (نسخه ۳.۱۱.۷) و در رایانه شخصی با پردازنده Intel Core i7-3720QM و ۳۲ گیگابایت رم اجرا شده اند. بخش‌های فرعی زیر، تنظیمات الگوریتم‌های دسته‌بندی پایه، معیارهای ارزیابی، معرفی الگوریتم SSL-WSC و تنظیمات مربوط به پارامترهای آن و همچنین نتایج حاصل از پیاده سازی‌ها را به تفصیل توضیح می‌دهند.

۴-۱- الگوریتم‌های دسته بندی کننده اساسی

در پیاده سازی روش پیشنهادی، آزمایش‌ها از درخت تصمیم[۱۶]، ماشین‌های بردار پشتیبان[۱۷]، رگرسیون لجستیک[۱۸]، K-نزدیک‌ترین همسایه[۱۹]، بیز ساده گوسی[۲۰]، دسته‌بندی جنگل تصادفی[۲۱]، پرسپترون چندلایه[۲۲] و تقویت گرادیان شدید[۲۳] (تک و گروهی) به عنوان الگوریتم‌های دسته بند پایه استفاده کرده اند. این دسته‌بندها برای اجرای الگوریتم نیمه نظارتی SSL-WSC با مجموعه داده جدید EQWS و مقایسه آن با اجرای همان الگوریتم بر روی مجموعه داده اولیه QWS مورد استفاده قرار گرفته اند.

جدول ۵ مقادیر پارامترهای اصلاح شده مورد استفاده برای دسته بندهای مختلف در آزمایش‌ها را نشان می‌دهد.

جدول ۵: پارامترهای اصلاح شده در تنظیمات دسته بندهای پایه

دسته بندهای پایه	تنظیمات پارامترها
Decision Tree	max_depth=3
SVM	probability = True
Logistic Regression	max_iter=1500
Random Forest Classifier	max_depth=25 n_estimators=10 max_features=1
MLP	solver='adam' alpha=1e-3 hidden_layer_sizes= (64,4) random_state=1
XGBoost	objective="multi: SoftMax" random_state=42 learning_rate=0.001 max_depth = 10 n_estimators = 15 eval_metric = 'mlogloss'

این جدول یک نمای کلی از مقادیر پارامترهای مورد استفاده برای هر دسته بند شامل نرخ یادگیری، حداکثر عمق، تعداد تخمین‌گرها[۲۴] و غیره ارائه می‌دهد. برای پارامترهایی که در جدول ذکر نشده اند

مقادیر پیش فرض ارائه شده است[۷].

۴-۲- معیارهای ارزیابی

پس از تولید مجموعه داده جدید EQWS و استفاده از دسته‌بندهای پایه ذکر شده در بخش قبلی، جهت آموزش و تست مدل عملکرد روش پیشنهادی را از نظر دقت، صحت و F1-Score ارزیابی کرده ایم. این ارزیابی به ما اجازه می‌دهد تا تأثیر ویژگی‌های اضافی را بر دقت دسته بندی بررسی کنیم.

در زمینه دسته بندی، هدف نهایی دستیابی به بالاترین دقت ممکن و شناسایی صحیح دسته‌ها است. ماتریس درهم ریختگی[۲۵] ابزاری است که عملکرد الگوریتم‌ها را در زمینه هوش مصنوعی نشان می‌دهد و ارزیابی جامع تر از عملکرد مدل از طریق آن امکان پذیر است (جدول ۶) [۲۳]. هر ستون ماتریس نشان دهنده کلاس پیش بینی شده برای هر داده (سرویس وب) است، در حالی که هر ردیف شامل کلاس واقعی هر داده است[۲۴]. روش پیشنهادی در این مقاله بر اساس معیارهای دقت، صحت و امتیاز F1 ارزیابی و با نتایج حاصل از پیاده سازی الگوریتم SSL-WSC با مجموعه داده اولیه مقایسه شده است.

جدول ۶: ماتریس درهم ریختگی

		Predicated Class: Positive	Predicated Class: Negative
Actual Class	Positive	True Positive (T.P.)	False Negative (F.N.) Type II Error
Actual Class	Negative	False Positive (F.P.) Type I Error	True Negative (T.N.)

دقت، نسبت نمونه‌های مثبت واقعی به تعداد کل نمونه‌های مثبت پیش بینی شده است. نمونه‌هایی که مدل به آنها به‌درستی برچسب مثبت می‌دهد به‌عنوان مثبت واقعی شناخته می‌شوند. از سوی دیگر، موارد مثبت کاذب، نمونه‌های منفی هستند که مدل به اشتباه آنها را به‌عنوان مثبت برچسب گذاری می‌کند(فرمول ۵).

$$Precision = \frac{TP}{TP + FP} \qquad (۵)$$

طبق فرمول ۶، صحت یک مدل را می‌توان با جمع کردن نمونه‌های مثبت واقعی و منفی واقعی و تقسیم آن بر مجموع تمام ورودی‌های ماتریس درهم ریختگی محاسبه کرد. مثبت واقعی و منفی واقعی به نمونه‌هایی اشاره دارد که به‌درستی توسط مدل دسته بندی شده و در قطر اصلی ماتریس درهم ریختگی قرار دارند.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \qquad (۶)$$

F1-Score یک معیار آماری است که برای ارزیابی عملکرد استفاده می‌شود که به‌عنوان میانگین‌هارمونیک بین یادآوری و دقت با وزن برابر محاسبه می‌شود (فرمول ۷). معمولاً در حوزه یادگیری ماشینی، شاخص F1-Score به طور گسترده ای برای ارزیابی دقت مدل‌های دسته‌بندی مورد استفاده قرار می‌گیرد [۲۵].

$$F1 - Score = \frac{2.Precision \times Recall}{Precision + Recall} = \frac{2.TP}{2.TP + FP + FN} \qquad (۷)$$

خطای نوع I یک مثبت کاذب است که در آن مدل وجود یک شرط را زمانی که وجود ندارد شناسایی می‌کند، و یک خطای نوع II یک منفی کاذب است که در آن مدل زمانی که وجود یک شرط وجود دارد، نتواند آن را تعیین کند. هر دو خطا بسته به موقعیت می‌توانند عواقب جدی داشته باشند[۲۶].

۴-۳- الگوریتم دسته‌بندی SSL-WSC

در این مقاله بهبود عملکرد الگوریتم قبلی خود یعنی SSL-WSC را با استفاده از افزایش ویژگی‌های مجموعه داده QWS مدنظر قرار داده ایم. از این رو تنظیمات پیش فرض را برای پیاده سازی روش پیشنهادی، همان تنظیمات پیاده سازی الگوریتم نیمه نظارتی SSL-WSC در نظر گرفته ایم [۷].

سناریوهای مختلفی در اجرای روش پیشنهادی در نظر گرفته شده است. اندازه بخش تست در داده‌های برچسب‌گذاری شده در پیاده‌سازی‌های مختلف روی ۲۰٪ و ۳۰٪ تنظیم شده است که این مقادیر در اکثر پیاده‌سازی‌های یادگیری ماشین، مقادیر متعارفی هستند. تعداد تکرارهای مرحله آموزش ۱۰، ۲۰، ۳۰ و ۴۰ در نظر گرفته شده که در هر تکرار مقادیر آستانه ۶۰، ۷۰، ۸۰ و ۹۰ لحاظ شده است که به‌صورت پویا به‌روز می‌شوند. توجه به این نکته ضروری است که نتایج بدست آمده در ادامه، از میانگین ۱۰ بار اجرای الگوریتم SSL-WSC با روش پیشنهادی در این مقاله و هر بار با بخش‌های مختلف داده‌های آموزشی و آزمایشی حاصل شده است. در ارائه الگوریتم SSL-WSC ، ما از روش دو مرحله ای برای انتخاب بخشی از داده‌های بدون برچسب برای افزودن به داده‌های برچسب‌دار استفاده کرده بودیم که یک مرحله ی آن از فاصله بین داده‌ها استفاده می‌کرد. در آن مقاله ما برای محاسبه فاصله از میان توابع فاصله شناخته شده از فاصله‌های ماهالانوبیس، منهتن و

مینکوفسکی به‌صورت اختیاری استفاده کردیم. نتایج حاصل از پیاده سازی الگوریتم نیمه نظارتی SSL-WSC نشان داده بود که روش ماهالانوبیس موثرترین روش برای محاسبه فاصله است. این یافته‌ها زمانی که اندازه بخش آزمون ۲۰ درصد از داده‌های برچسب‌گذاری در نظر گرفته شده بود حاصل شده بودند. بنابراین، در مقاله حاضر نیز نتایج روش پیشنهادی تنها برای این موارد خاص گزارش می‌شود.

به‌طور معمول، محاسبه فاصله ماهالانوبیس زمانی استفاده می‌شود که بین ویژگی‌های مجموعه داده همبستگی وجود داشته باشد. در مورد مجموعه داده QWS، بین ویژگی‌های مختلف، مانند زمان پاسخ با تاخیر و توان عملیاتی، و قابلیت دسترسی با سایر ویژگی‌ها همبستگی وجود دارد. بنابراین استفاده از روش ماهالانوبیس برای محاسبه فاصله برای این مجموعه داده مناسب می‌باشد و مقادیر لازم از فرمول ۸ بدست آمده است: با فرض داشتن دو داده $B = (b_1, b_2, \dots b_d)$ و $A = (a_1, a_2, \dots, a_d)$، فاصله ماهالانویس بین A و B با استفاده از فرمول زیر محاسبه می‌شود:

$$dist_{Mahalanobis}(A, B) = \sqrt{\sum_{i=1}^{d} \frac{(a_i - b_i)^2}{v_i^2}} \quad (۸)$$

به نحوی که $V = (v_1, v_2, \dots v_d)$ انحراف معیار A و B بوده و d ابعاد بردارهاست.

۴-۴- تاثیر ویژگی‌های جدید در کارائی الگوریتم SSL-WSC

در این مقاله، برای ارزیابی معیارهای F1-Score، صحت و دقت از سه پارامتر میانگین (Avg)، بیشینه مقدار (Max) و انحراف معیار (Std)، استفاده شده است. جدول ۷ نتایج پیاده سازی الگوریتم نیمه نظارتی SSL-WSC را هم با مجموعه داده اولیه QWS و هم مجموعه داده جدید EQWS برای دسته بندهای پایه مختلف جهت کلاس بندی سرویس‌های وب مبتنی بر کیفیت مقایسه می‌کند.

جدول۷: مقادیر میانگین، بیشینه مقدار، و انحراف معیار بدست آمده از اجرای الگوریتم SSL-WSC با مجموعه داده پیشنهاددی EQWS و مجموعه داده اصلی QWS برای معیارهای ارزیابی F1-score، صحت و دقت

			Decision Tree	SVM	Logistic Regression	k-Nearest Neighbors	Naive Bayes	Random Forest	Multilayer Perceptron	XGboost (Ensemble)	XGboost (Single)
F1-Score	EQWS	Avg	45.67%	27.47%	48.09%	47.11%	41.12%	50.67%	24.06%	47.85%	48.22%
		Max	48.67%	38.36%	55.07%	56.88%	48.85%	62.25%	28.86%	56.03%	55.99%
		Std	0.0172	0.0616	0.0425	0.0545	0.0477	0.0717	0.0331	0.0594	0.0648
	QWS	Avg	40.84%	23.77%	43.91%	46.22%	36.91%	48.41%	36.69%	44.51%	41.07%
		Max	47.07%	30.6%	52.21%	52.27%	47.63%	56.22%	43.49%	52.37%	46.83%
		Std	0.0479	0.0497	0.0481	0.0447	0.0539	0.0359	0.0435	0.0402	0.0498
	میزان بهبود الگوریتم SSL-WSC با مجموعه داده EQWS		**11.83%**	**15.58%**	**9.53%**	**1.92%**	**11.43%**	**4.67%**	**-34.41%**	**7.51%**	**17.40%**
صحت	EQWS	Avg	47.95%	37.81%	48.63%	47.67%	42.19%	50.96%	34.11%	47.95%	48.49%
		Max	52.05%	46.58%	56.16%	57.53%	49.32%	63.01%	36.99%	56.16%	56.16%
		Std	0.0212	0.0438	0.0421	0.0561	0.0382	0.0730	0.0290	0.0558	0.0628
	QWS	Avg	43.42%	36.44%	44.52%	46.58%	38.63%	48.63%	39.45%	44.66%	41.23%
		Max	49.32%	39.73%	52.05%	52.05%	49.32%	56.16%	46.58%	52.05%	46.57%
		Std	0.0438	0.0254	0.043	0.0463	0.0485	0.0359	0.0474	0.0374	0.0496
	میزان بهبود الگوریتم SSL-WSC با مجموعه داده EQWS		**10.41%**	**3.76%**	**9.23%**	**2.35%**	**9.22%**	**4.79%**	**-13.54%**	**7.36%**	**17.61%**
دقت	EQWS	Avg	49.72%	31.08%	49.67%	49.66%	46.37%	51.40%	29.40%	48.63%	49.24%
		Max	56.75%	59.81%	56.23%	59.57%	55.15%	65.49%	47.41%	56.86%	56.16%
		Std	0.0425	0.1148	0.0441	0.0544	0.0636	0.0784	0.1053	0.0625	0.0600
	QWS	Avg	44.29%	24.78%	44.70%	48.62%	44.17%	49.67%	37.05%	45.85%	41.94%
		Max	57.91%	59.32%	52.81%	55.06%	54.67%	59.07%	42.67%	53.40%	48.72%
		Std	0.066	0.1323	0.0463	0.041	0.0567	0.042	0.0334	0.0479	0.0519
	میزان بهبود الگوریتم SSL-WSC با مجموعه داده EQWS		**12.25%**	**25.46%**	**11.12%**	**2.14%**	**5.00%**	**3.50%**	**-20.64%**	**6.06%**	**17.41%**

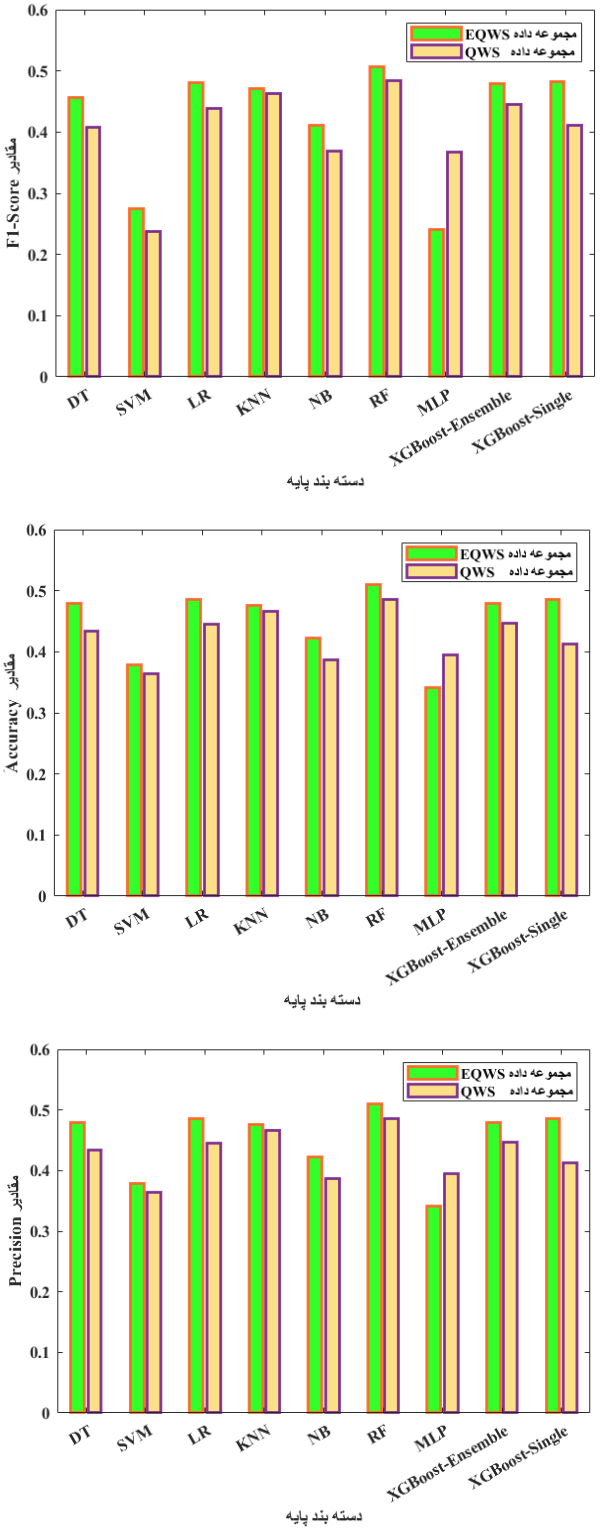
همانطور که نتایج ارائه شده در جدول ۷ نشان می‌دهد، به‌غیر از الگوریتم پایه پرسپترون چندلایه، پیاده سازی روش پیشنهادی نتایج قابل توجهی را در هر سه معیار برای اکثر دسته بندها به‌همراه دارد. برای معیارهای F1-Score و صحت، دسته‌بند پایه تقویت گرادیان شدید (تنها) حداکثر بهبود ۱۷.۴۰٪ و ۱۷.۶۱٪ را به‌ترتیب نشان می‌دهد و برای معیار دقت، دسته بندی کننده ماشین بردار پشتیبان حداکثر بهبود ۲۵.۴۶٪ را نشان می‌دهد. به‌طور کلی، می‌توان نتیجه گرفت که روش پیشنهادی با مجموعه داده جدید، نسبت به مجموعه داده اصلی، عملکرد الگوریتم SSL-WSC را در غالب دسته‌بندهای پایه و معیارهای ارزیابی بهبود بخشیده است و بیشترین پیشرفت در دسته‌بند تقویت گرادیان شدید مشاهده شده است. به‌طور متوسط، روش پیشنهادی مقادیر سه معیار ارزیابی F1-Score، صحت و دقت را به‌ترتیب ۵.۰۵٪، ۵.۶۹٪ و ۶.۹۲٪ افزایش داده است. بنابراین، استفاده از مجموعه داده EQWS با ویژگی‌های بیشتر در روش پیشنهادی برای ایجاد مدل‌های دسته‌بندی می‌تواند بهتر از روش قبلی با مجموعه داده اولیه عمل کند.

همچنین مقادیر کوچک انحراف معیار در روش پیشنهادی برای برخی الگوریتم‌های دسته بند نسبت به روش اصلی نشان می‌دهد که اجرای الگوریتم SSL-WSC توسط مجموعه داده پیشنهادی نیز همانند روش اصلی، بهینه عمل می‌کند و درنتیجه الگوریتم پایدار است.

شکل ۳ یک نمایش گرافیکی از میانگین نتایج بدست آمده برای معیارهای F1-Score، صحت و دقت را برای مقایسه بهتر نشان می‌دهد. همانطور که در شکل‌ها نشان داده شده است، افزایش ویژگی‌های کیفی غیرعملکردی جدید به مجموعه داده QWS در راستای برچسب زدن داده‌های بدون برچسب و به طبع آن دسته بندی دقیق تر داده‌ها با مجموعه داده جدید عملکرد بهتری نسبت به مجموعه داده اولیه با استفاده از الگوریتم SSL-WSC دارد.

۴-۵- بحث

داشتن ویژگی‌ها مناسب در مجموعه داده‌های مربوط به سرویس‌های وب مبتنی برکیفیت می‌تواند در بهبود دسته بندی سرویس‌ها کمک شایانی نماید. ولی با توجه به سختی جمع آوری اطلاعات مربوط به ویژگی‌ها، می‌توان با در نظر گرفتن ارتباط بین ویژگی‌ها، از طریق مهندسی ویژگی مقادیری برای ویژگی‌های جدید محاسبه نمود که این امر می‌تواند در شرایط خاص برای دسته بندی سرویس‌های وب با عملکرد مشابه نتایج مطلوبی از خود بجا بگذارد.



شکل ۳- مقایسه پیاده سازی الگوریتم SSL-WSC با استفاده از مجموعه داده اولیه QWS و مجموعه داده جدید EQWS از نظر معیارهای F1-Score، صحت و دقت

۵- نتیجه‌گیری و پیشنهادها برای کارهای آینده

اینترنت بستری را برای به اشتراک گذاری سرویس‌ها فراهم می‌کند و کارگزاران سرویس وب به کاربران کمک می‌کنند تا بر اساس رتبه بندی، سرویس مناسب را از بین طیف وسیعی از سرویس‌های مشابه انتخاب کنند. کیفیت سرویس‌ها در ارزیابی سرویس‌های مورد نیاز کاربر مهم است. با این حال، گردآوری اطلاعات در رابطه با ویژگی‌های کیفی سرویس‌ها امری چالش برانگیز و زمان بر می‌باشد. در نتیجه، ارائه دهندگان سرویس‌ها به تکنیک‌های داده کاوی و یادگیری ماشین متوسل می‌شوند تا اطمینان حاصل کنند که کاربران بهترین سرویس‌های ممکن را دریافت می‌کنند و از طبقه بندی خدمات برای شناسایی مناسب ترین سرویس استفاده می‌کنند. با این حال تعداد کمِ ویژگی‌های موجود در مجموعه‌های داده‌ها باعث گردیده است در این مقاله از روش مهندسی ویژگی برای ایجاد ویژگی‌های جدید از ویژگی‌های موجود در مجموعه داده‌ها استفاده کنیم. نتایج آزمایش‌ها نشان می‌دهد فرآیند ارتقای مجموعه داده معروف QWS با افزودن ویژگی‌های جدید همچون قابلیت همکاری، امنیت، مقیاس‌پذیری و استحکام برگرفته از ویژگی‌های موجود، به‌طور قابل‌توجهی دقت دسته‌بندی سرویس وب را نسبت به مجموعه داده اصلی تحت اجرای الگوریتم نیمه نظارتی SSL-WSC بهبود می‌بخشد.

مجموعه داده‌ی غنی شده EQWS نمایش جامع تری از ویژگی‌های سرویس وب ارائه می‌دهد و در نتیجه کارایی مدل‌های دسته بندی را افزایش می‌دهد. این رویکرد دارای پتانسیلی بالایی برای ارتقای پیشرفته دسته بندی سرویس‌های وب می‌باشد و پیامدهایی برای کاربردهای مختلف در محاسبات سرویس گرا دارد. تحقیقات آینده می‌تواند تکنیک‌های مهندسی ویژگی‌های پیشرفته‌تر را بررسی کند و ادغام دانش خاص دامنه را برای غنی‌سازی بیشتر مجموعه داده در نظر بگیرد. علاوه بر این، استفاده از روش‌های مجموعه و معماری‌های یادگیری عمیق برای دسته‌بندی سرویس‌های وب با استفاده از مجموعه داده‌های تقویت‌شده می‌تواند یک راه جالب برای بررسی باشد.

مراجع

[1] M. M. Amin, A. Sutrisman, D. Stiawan, E. Ermatita, M. Y. Alzahrani, and R. Budiarto, "Interoperability framework for integrated e-health services," *Bulletin of Electrical Engineering and Informatics*, vol. 9, no. 1, pp. 354-361, 2020.

[2] M. Masdari, M. Nozad Bonab, and S. Ozdemir, "QoS-driven metaheuristic service composition schemes: a comprehensive overview," *Artificial Intelligence Review*, vol. 54, pp. 3749-3816, 2021.

[3] B. Al-Shargabi, S. Al-Jawarneh, and S. Hayajneh, "A cloudlet based security and trust model for e-government web services," *Journal of Theoretical and Applied Information Technology*, vol. 98, no. 1, pp. 27-37, 2020.

[4] G. Moritz, F. Golatowski, and D. Timmermann, "A lightweight SOAP over CoAP transport binding for resource constraint networks," in *2011 IEEE eighth international conference on mobile ad-hoc and sensor systems*, 2011: IEEE, pp. 861-866.

[5] M. S. Das, A. Govardhan, and D. V. Lakshmi, "Classification of web services using data mining algorithms and improved learning model," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 17, no. 6, pp. 3191-3202, 2019.

[6] H. Ye, B. Cao, Z. Peng, T. Chen, Y. Wen, and J. Liu, "Web services classification based on wide & Bi-LSTM model," *IEEE Access*, vol. 7, pp. 43697-43706, 2019.

[7] M. N. Bonab, J. Tanha, and M. Masdari, "A Semi-supervised Learning Approach to Quality-based Web Service Classification," *IEEE Access*, 2024.

[8] E. Al-Masri and Q. H. Mahmoud, "Qos-based discovery and ranking of web services," in *2007 16th international conference on computer communications and networks*, 2007: IEEE, pp. 529-534.

[9] S. L. Brunton, B. R. Noack, and P. Koumoutsakos, "Machine learning for fluid mechanics," *Annual review of fluid mechanics*, vol. 52, pp. 477-508, 2020.

[10] M. J. Kaur, V. P. Mishra, and P. Maheshwari, "The convergence of digital twin, IoT, and machine learning: transforming data into action," *Digital twin technologies and smart cities*, pp. 3-17, 2020.

[11] M. Hasnain, I. Ghani, M. F. Pasha, and S. R. Jeong, "Machine learning methods for trust-based selection of web services," *KSII Transactions on Internet and Information Systems (TIIS)*, vol. 16, no. 1, pp. 38-59, 2022.

[12] J. Tanha, M. Van Someren, and H. Afsarmanesh, "Semi-supervised self-training for decision tree classifiers," *International Journal of Machine Learning and Cybernetics*, vol. 8, pp. 355-370, 2017.

[13] F. Nargesian, H. Samulowitz, U. Khurana, E. B. Khalil, and D. S. Turaga, "Learning Feature Engineering for Classification," in *Ijcai*, 2017, vol. 17, pp. 2529-2535.

[14] I. Guyon and A. Elisseeff, "An introduction to feature extraction," in *Feature extraction: foundations and applications*: Springer, 2006, pp. 1-25.

[15] V. Kumar and S. Minz, "Feature selection," *SmartCR*, vol. 4, no. 3, pp. 211-229, 2014.

[16] P. Rodriguez-Mier, C. Pedrinaci, M. Lama, and M. Mucientes, "An integrated semantic web service discovery and composition framework," *IEEE transactions on services computing*, vol. 9, no. 4, pp. 537-550, 2015.

[17] J. M. Kanter and K. Veeramachaneni, "Deep feature synthesis: Towards automating data science endeavors," in *2015 IEEE international conference on data science and advanced analytics (DSAA)*, 2015: IEEE, pp. 1-10.

[18] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *The journal of machine learning research*, vol. 15, no. 1, pp. 1929-1958, 2014.

[19] Z. L. Chia, M. Ptaszynski, F. Masui, G. Leliwa, and M. Wroczynski, "Machine Learning and feature engineering-based study into sarcasm and irony classification with application to cyberbullying detection," *Information Processing & Management*, vol. 58, no. 4, p. 102600, 2021.

[20] I. Sommerville, *Engineering software products*. Pearson London, 2020.

[21] D. Thomas and A. Hunt, *The Pragmatic Programmer: your journey to mastery*. Addison-Wesley Professional, 2019.

[22] B. Burns, *Designing distributed systems: patterns and paradigms for scalable, reliable services*. " O'Reilly Media, Inc.", 2018.

[23] M.-T. Wu, "Confusion matrix and minimum cross-entropy metrics based motion recognition system in the classroom," *Scientific Reports*, vol. 12, no. 1, p. 3095, 2022.

[24] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, "Evaluating trust prediction and confusion

matrix measures for web services ranking," *Ieee Access*, vol. 8, pp. 90847-90861, 2020.

[25] M. Grandini, E. Bagli, and G. Visani, "Metrics for multi-class classification: an overview," *arXiv preprint arXiv:2008.05756*, 2020.

[26] S. Ruuska, W. Hämäläinen, S. Kajava, M. Mughal, P. Matilainen, and J. Mononen, "Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle," *Behavioural processes*, vol. 148, pp. 56-62, 2018.

پاورقی‌ها:

[1] Web Brokers
[2] SOAP (Simple Object Access Protocol)
[3] UDDI (Universal Description, Discovery, and Integration)
[4] WSDL (Web Service Description Language)
[5] XML (Extensible Markup Language)
[6] HTTP (Hypertext Transfer Protocol)
[7] QoS (Quality of service)
[8] Precision
[9] Accuracy
[10] Principal Component Analysis
[11] Singular Value Decomposition
[12] Correlation Analysis
[13] Mutual Information.
[14] Overfitting
[15] Collaborative Filtering
[16] Decision Tree
[17] Support Vector Machine
[18] Logistic Regression
[19] KNN (k-nearest neighbors)
[20] Naive Bayes
[21] Random Forest
[22] Multilayer Perceptron
[23] XGBoost
[24] Estimators
[25] Confusion Matrix