

ارائه یک روش فازی-تکاملی برای تشخیص خطاهای نرم افزار

مهدي افتخاري*، مريم مجيدي مؤمن آبادي و مجتبي خمر

بخش مهندسي کامپيوتر، دانشکده فني و مهندسي، دانشگاه شهيد باهنر کرمان، کرمان، ايران

چکیده

تشخيص خطاهای نرم افزار، یکی از بزرگ ترین چالش های توسعه نرم افزار است و بیش ترين بودجه را در فرآیند توسعه نرم افزار به خود اختصاص می دهد. با توجه به اهمیت تشخيص خطاهای نرم افزار، در این مقاله روشی بر مبنای مجموعه های فازی و الگوریتم های تکاملی ارائه می شود. از آن جا که ماهیت مجموعه داده های تشخيص خطای نرم افزار نامتوازن است، از مزایای الگوریتم های خوشه بندی فازی به منظور نمونه برداری از داده ها و توجه بیشتر به طبقه اقلیت استفاده شده است. روش پیشنهادی در واقع یک الگوریتم ترکیبی است که در ابتدا از روش خوشه بندی c میانگین فازی به منظور نمونه برداری بوت استرپ وزن دار استفاده می شود. وزن داده ها همان درجه عضویت آنهاست و درجه عضویت داده های طبقه اقلیت افزایش می یابد. در گام بعدی، از الگوریتم خوشه بندی کاهش برای ایجاد طبقه بند استفاده می شود که توسط داده های تولید شده در مرحله قبل آموزش می بیند؛ همچنین از الگوریتم ژنتیک دودویی برای انتخاب ویژگی های مناسب استفاده می شود. نتایج به دست آمده و همچنین مقایسه آنها با چندین روش معروف در این زمینه، کارایی مناسب روش پیشنهادی را نشان می دهد. برای انجام آزمایش ها از ده پایگاه داده معروف با گستره وسیعی از اندازه و نرخ عدم توازن، استفاده شده است و برای تأیید نتایج از آزمون آماری تی بهره برده ایم.

واژگان کلیدی: الگوریتم های تکاملی، تشخيص خطای نرم افزار، طبقه بندی، مجموعه داده های نامتوازن، منطق فازی.

Proposing an evolutionary-fuzzy method for software defects detection

Mahdi Eftekhari, Maryam Majidi momenabadi & Mojtaba Khamar
Department computer engineering, Shahid Bahonar University of Kerman, Kerman, Iran.

Abstract

Software defects detection is one of the most important challenges of software development and it is the most prohibitive process in software development. The early detection of fault-prone modules helps software project managers to allocate the limited cost, time, and effort of developers for testing the defect-prone modules more intensively. In this paper, according to the importance of software defects detection, a method based on fuzzy sets and evolutionary algorithms is proposed. Due to the imbalanced nature of software defect detection datasets, benefits of fuzzy clustering algorithms were used to data sampling and more attention to the minority class. This method is a combined algorithm which, firstly has used fuzzy c-mean clustering as weighted bootstrap sampling. Weight of data (their membership's degrees) increases for minority class. In the next step, the subtractive clustering algorithm is applied to produce the classifier which was trained by produced data in the previous step. The binary genetic algorithm was utilized to select appropriate features. The results and also comparisons with eight popular methods in software defect detection literature, show an acceptable performance of the proposed method. The experiments were performed on ten real-world datasets with a wide range of data sizes and imbalance rates. Also T-test is used as the statistical significance test for pair wise comparison of our proposed method against the others. The final results of T-test are shown in tables

* نویسنده عهده دار مکاتبات . تاریخ ارسال مقاله: ۱۳۹۶/۶/۲۴ . تاریخ آخرین بازنگری: ۱۳۹۷/۶/۱۴ . تاریخ پذیرش: ۱۳۹۷/۱۰/۱۹ . Corresponding author

for three performance measures (G-mean, AUC and Balanced) over various datasets. (As the obtained results apparently show our proposed method has the ability to improve three aforementioned performance criteria simultaneously). Some methods just have improved the G-mean measure while the AUC and Balance criteria have lower values than the others. Securing a high level of three performance measures simultaneously illustrates the ability of our proposed algorithm for handling the imbalance problem of software defects detection datasets.

Keywords: classification, evolutionary algorithm, fuzzy logic, imbalance datasets, software defect detection.

مسأله تشخیص خطای نرم‌افزار، یک نمونه خطا نسبت به یک نمونه بدون خطا، به احتمال کم‌تری اتفاق می‌افتد؛ بنابراین داده‌های تشخیص خطای نرم‌افزار نامتوازن هستند؛ به این معنا که تعداد نمونه‌های طبقه بدون خطا بیشتر از تعداد نمونه‌های طبقه خطادار است؛ بنابراین تمرکز این مقاله بر روی مسئله طبقه‌بندی با توزیع نامتوازن طبقه است.

مدل‌های تشخیص خطای نرم‌افزار می‌توانند ماژول‌های نرم‌افزاری را به دو طبقه ماژول‌های خطادار و بدون خطا اختصاص دهند؛ اما استفاده از طبقه‌بندی استاندارد برای مسائل نامتوازن مناسب نیست؛ زیرا اغلب الگوریتم‌های یادگیری ماشین فرض می‌کنند که تعداد نمونه‌های آموزشی در طبقه‌های متفاوت برابر است. در نتیجه طبقه‌بندی یادگرفته‌شده اغلب از طبقه اکثریت نتیجه می‌شود که این موضوع به دلیل آن که آموزش طبقه اقلیت به‌درستی انجام نشده است به پیش‌بینی بسیار ضعیف از طبقه اقلیت منجر می‌شود. بنابراین کنترل و حل مسأله داده نامتوازن برای بهبود کارایی پیش‌بینی‌کننده‌های خطای نرم‌افزار امری ضروری است. روش‌های عددی برای حل مسائل داده نامتوازن به دو دسته اصلی تقسیم می‌شوند:

۱. نمونه‌گیری از داده که خود به سه دسته زیاد کردن طبقه اقلیت، کم کردن طبقه اکثریت و روش‌های ترکیبی تقسیم می‌شود.

۲. اصلاح الگوریتم‌های موجود یا ارائه یک الگوریتم جدید که شامل سه روش یادگیری حساس به هزینه، یادگیری مبتنی بر هسته و یادگیری مبتنی بر تشخیص است [5].

در صورتی که یک نمونه، خطادار باشد، ولی به اشتباه آن را بدون خطا طبقه‌بندی کنیم، کیفیت نرم‌افزار به شدت پایین می‌آید. در حالی که طبقه‌بندی اشتباه یک نمونه بدون خطا به عنوان خطادار، هزینه آزمایش فقط یک ماژول را در پی خواهد داشت. بنابراین هزینه طبقه‌بندی اشتباه طبقه اقلیت، بسیار بیشتر از هزینه طبقه‌بندی اشتباه طبقه اکثریت است. با توجه به این مسأله، بسیار مهم است که بتوانیم طبقه خطادار یا همان طبقه اقلیت را به‌درستی پیش‌بینی کنیم [1].

۱- مقدمه و پیشینه

در سال ۲۰۰۵ که منبع داده پرومیس^۱ تولید شد، این امکان به پژوهش‌گران داده شد که بتوانند مطالعات و آزمایش‌های خود را با هم مقایسه کنند. در این منبع داده، مجموعه داده‌های خطای نرم‌افزار وجود دارد که بر اساس ویژگی‌های مختلف نرم‌افزار، خطاهای نرم‌افزار را در دسته‌های مختلف دسته‌بندی می‌کنند. پس از آن، پژوهش‌ها در زمینه تشخیص خطای نرم‌افزار بسیار افزایش پیدا کرد [1].

با افزایش اندازه و پیچیدگی سامانه‌های نرم‌افزاری، صنعت نرم‌افزار با چالش تحویل سامانه باکیفیت، قابل اعتماد، به‌موقع و با هزینه تعیین شده مواجه شد. برای کیفیت، تعاریف زیادی وجود دارد؛ اما یکی از تعاریف قابل قبول برای کیفیت بالا، خطای کم است [2]. خطاهای نرم‌افزاری به‌طور معمول به‌عنوان انحراف از خصوصیات مورد انتظار است که منجر به شکست‌هایی در عمل در زمان آینده می‌شود.

برای کم کردن خطای سامانه‌های نرم‌افزاری به آزمایش نرم‌افزار نیاز است؛ اما حدود ۵۰ تا ۶۰ درصد هزینه توسعه نرم‌افزار به آزمایش مربوط می‌شود [3]. به دلیل هزینه‌بر بودن آزمایش کلیه ماژول‌های یک سامانه نرم‌افزاری بزرگ، لازم است، فقط ماژول‌هایی که احتمال خطای بیشتری دارند، آزمایش شوند؛ بنابراین احتیاج به تشخیص ماژول‌های مستعد خطا^۲ پیدا شد. با تشخیص ماژول‌های مستعد خطا در ابتدای یک پروژه نرم‌افزاری، مدیران پروژه‌های نرم‌افزاری می‌توانند زمان، هزینه و تلاش تیم توسعه را بیشتر صرف آزمایش ماژول‌های مستعد خطا کنند و دیگر نیاز به آزمایش کل سامانه نرم‌افزاری نیست. آنها همچنین می‌توانند برای پیشبرد پروژه نرم‌افزاری برنامه‌ریزی، کنترل و اجرای بهتر داشته باشند و با تحویل سامانه با کیفیت، با هزینه تعیین شده و به‌موقع رضایت مشتری را بیشتر جلب می‌کنند [4]. نکته بسیار مهم این است که ماژول‌های مستعد خطا، بخش کوچکی از کل سامانه نرم‌افزار را تشکیل می‌دهند. به عبارت دیگر، به دلیل ماهیت

¹ PROMISE

² Defect-prone modules

تعداد زیادی خطا هستند، استفاده می‌شود، در مقایسه با دیدگاه رگرسیون بردار پشتیبان، رگرسیون بردار پشتیبان فازی می‌تواند میانگین مربعات خطای کمتر و دقت بیشتری در تعداد کل خطاها به دست آورد. رُسلی و همکارانش در سال ۲۰۱۱ با استفاده از الگوریتم ژنتیک کاربردی برای پیش‌بینی خطای نرم‌افزار طراحی [10] و برای انجام آزمایش‌های خود، از معیارهای یک نرم‌افزار منبع باز به‌عنوان ورودی الگوریتم ژنتیک استفاده کردند. هدف آنها از طراحی پیشنهادشده، توسعه یک ابزار خودکار برای توسعه‌دهندگان نرم‌افزار است که بتوانند تشخیص دهند کدام ماژول‌های نرم‌افزاری احتمال بیشتری دارد که در آینده باعث ایجاد مشکل شوند.

بخش‌های بعدی مقاله به شرح زیر ارائه خواهد شد: در بخش دو به توضیح در مورد روش خوشه‌بندی فازی استفاده‌شده در این مقاله پرداخته می‌شود. در بخش سه روش پیشنهادی توضیح داده شده است. در بخش چهارم به تحلیل و بحث در مورد نتایج پرداخته می‌شود و در بخش پنجم با نتیجه‌گیری که حاصل بررسی روش پیشنهادی و دیگر روش‌ها می‌باشد مقاله پایان می‌یابد.

۲- خوشه‌بندی فازی

خوشه‌بندی یکی از شاخه‌های یادگیری بدون نظارت، و فرآیند خودکاری است که در طی آن، نمونه‌ها به دسته‌هایی که اعضای آن مشابه یکدیگرند، تقسیم می‌شوند که به این دسته‌ها خوشه گفته می‌شود. برای مشابه‌بودن می‌توان معیارهای مختلفی مثل معیار فاصله را در نظر گرفت که در آن اشیای نزدیک‌تر به هم به‌عنوان یک خوشه در نظر گرفته می‌شود. به این نوع خوشه‌بندی، خوشه‌بندی مبتنی بر فاصله نیز گفته می‌شود. در خوشه‌بندی کلاسیک، هر نمونه ورودی متعلق به یک و فقط یک خوشه است و نمی‌تواند عضو دو خوشه و یا بیش‌تر باشد و به زبان دیگر خوشه‌ها هم‌پوشانی ندارند. حال، حالتی را در نظر بگیرید که میزان تشابه یک نمونه با دو خوشه و یا بیش‌تر یکسان باشد. تفاوت اصلی خوشه‌بندی کلاسیک و خوشه‌بندی فازی در این است که در خوشه‌بندی فازی، یک نمونه می‌تواند متعلق به بیش از یک خوشه باشد. چنان‌چه ایده روشی در مورد تعداد خوشه‌ها وجود نداشته باشد، استفاده از خوشه‌بندی کاهشی روشی سریع برای حل این موضوع محسوب می‌شود. گاهی اوقات مراکزی که با این روش تخمین زده شده‌اند، به‌عنوان نقاط اولیه برای دیگر الگوریتم‌های خوشه‌بندی مورد استفاده قرار می‌گیرند. خوشه‌بندی کاهشی که خوشه‌بندی تفاضلی نیز

مدل‌های پیش‌بینی خطا که رابطه بین معیارهای نرم‌افزار و ماژول‌های مستعد خطا را پیدا می‌کنند، از روش‌های مختلف پیش‌بینی استفاده کرده‌اند. از جمله مهم‌ترین و متداول‌ترین آنها می‌توان به روش‌های طبقه‌بندی فازی [5]-[7]، الگوریتم‌های تکاملی [10]-[8]، شبکه‌های عصبی مصنوعی [13]-[7]، [5]-[2]، ماشین‌های بردار پشتیبان [8]-[19]-[12]، [10] اشاره کرد.

وانگ و همکارش در سال ۲۰۱۲ در مورد این مسأله پژوهش کردند که چه‌طور روش‌های یادگیری طبقه‌های نامتوازن می‌توانند به حل مسأله تشخیص خطای نرم‌افزار کمک کنند [1]. آنها انواع مختلف روش‌های یادگیری طبقه‌های نامتوازن را (در قالب هفت الگوریتم) بررسی کردند که شامل سه نوع روش نمونه‌گیری مجدد، روش‌های حرکت حد آستانه^۱ و الگوریتم‌های جمعی^۲ می‌شدند. برای به‌دست‌آوردن بیشینه پتانسیل هر یک از روش‌ها، در ابتدا آنها بهترین مقادیر پارامترها را برای هر روش جستجو کردند. این جستجو برای به‌دست‌آوردن بهترین پارامترها مبتنی بر معیارهای تعادل، میانگین هندسی و سطح زیر نمودار^۳ انجام شد؛ سپس بهترین مقادیر پارامترها برای هر روش تنظیم و الگوریتم‌ها با یکدیگر مقایسه شدند. نتیجه مقایسه این روش‌ها این بود که الگوریتم آدابوست ان سی^۴ بهترین کارایی را در معیارهای میانگین هندسی، سطح زیر نمودار و تعادل به‌دست آورد. آنها برای ارتقای کارایی الگوریتم آدابوست ان سی، یک نسخه پویا از آن پیشنهاد دادند و نام الگوریتم پیشنهادی خود را آدابوست ان سی پویا^۵ گذاشتند. الگوریتم آنها قادر است، در حین یادگیری، پارامترهای خود را تنظیم کند؛ بدون آن‌که نیاز باشد هیچ پارامتری از قبل تعریف شود. در انتها آنها الگوریتم خود را با الگوریتم‌های آدابوست ان سی و بیز ساده^۶ مقایسه کردند. آنها گزارش دادند که روش پیشنهادی‌شان کارآمدتر و مؤثرتر از آدابوست ان سی اصلی و بیز ساده است. یان و همکارانش در سال ۲۰۱۰ یک روش جدید با استفاده از رگرسیون بردار پشتیبان فازی^۷ برای تشخیص تعداد خطاهای نرم‌افزار پیشنهاد کردند [6]. ورودی فازی‌ساز رگرسیون می‌تواند مجموعه داده‌های معیارهای نرم‌افزار نامتعادل را مدیریت کند. نتایج آزمایش‌های آنها روی مجموعه داده‌های MIS و RSDIMU نشان داد وقتی از ماژول‌هایی که شامل

¹ Threshold-moving

² Ensemble learning

³ Area Under Curve(AUC)

⁴ AdaBoost.NC

⁵ Dynamic version of AdaBoost.NC(DNC)

⁶ Naive Bayes

⁷ Fuzzy Support Vector Regression (FSVR)

$$z = \frac{\sum_{i=1}^N w_i f_i}{\sum_{i=1}^N w_i} \quad (6)$$

که w_i قدرت شلیک^۲ قانون i ام را بیان می‌کند.

۲-۱- خوشه بندی فازی c - میانگین

مشابه الگوریتم c -میانگین کلاسیک در این الگوریتم نیز تعداد خوشه‌ها (c) از قبل مشخص شده است. تابع هدفی که برای این الگوریتم تعریف شده به صورت زیر است [15], [20]:

$$J = \sum_{i=1}^c \sum_{k=1}^n u_{ik} d_{ik}^2 \quad (7)$$

$$= \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m \|x_k - v_i\|^2$$

در فرمول بالا m یک عدد حقیقی بزرگ‌تر از یک است که در بیش‌تر موارد برای m عدد دو انتخاب می‌شود. x_k نمونه k ام و v_i نماینده یا مرکز خوشه i ام است. u_{ik} میزان تعلق نمونه k ام در خوشه i ام را نشان می‌دهد. علامت $\| \cdot \|$ میزان تشابه (فاصله) نمونه با (از) مرکز خوشه است که می‌توان از هر تابعی که بیان‌گر تشابه نمونه و مرکز خوشه باشد، استفاده کرد. از روی u_{ik} می‌توان یک ماتریس u تعریف کرد که دارای c سطر و n ستون است و مؤلفه‌های آن می‌توانند هر مقداری بین صفر تا یک را اختیار کنند. اگر تمامی مؤلفه‌های ماتریس u به صورت صفر و یا یک باشند، الگوریتم مشابه c - میانگین کلاسیک خواهد بود. با این‌که مؤلفه‌های ماتریس u می‌توانند هر مقداری بین صفر تا یک را اختیار کنند، اما مجموع مؤلفه‌های هر یک از ستون‌ها باید برابر یک باشد و داریم [6], [20]:

$$\sum_{i=1}^c u_{ik} = 1, \forall k = 1, \dots, n \quad (8)$$

معنای این شرط این است که مجموع تعلق هر نمونه به c خوشه باید برابر یک باشد. با استفاده از شرط بالا و کمینه‌کردن تابع هدف خواهیم داشت [6], [20]:

$$u_{ik} = \left(\frac{1}{\sum_{j=1}^c \frac{d_{jk}^2}{d_{jk}^{2/m-1}}} \right)^{2/m-1} \quad (9)$$

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \quad (10)$$

² Firing strength

نامیده می‌شود، در اصل یک فرم تغییر یافته از روش خوشه‌بندی کوهستان^۱ است. در این الگوریتم هر نقطه به‌عنوان یک پتانسیل برای مرکز خوشه در نظر گرفته می‌شود که اندازه‌گیری پتانسیل طبق معادله^۱ زیر به دست می‌آید [6]:

$$P_i = \sum_{j=1}^N e^{\alpha \|x_i - x_j\|^2} \quad (1)$$

$$\alpha = \frac{4}{(r_a)^2} \quad (2)$$

که x_i بیان‌گر نمونه i ام است. هم‌چنین مقدار α طبق رابطه^۲ (۲) به دست می‌آید. $r_a > 0$ مقداری مثبت است که به‌عنوان شعاع همسایگی برای هر مرکز خوشه تعریف می‌شوند. بنابراین پتانسیل تخصیص داده شده به هر خوشه به فاصله آن از نقاط دیگر وابسته است و در مواردی با همسایه متراکم، منجر به خوشه‌هایی با پتانسیل بالا می‌شود. بعد از محاسبه پتانسیل برای هر نقطه، یک نقطه که دارای بالاترین پتانسیل است به‌عنوان مرکز خوشه انتخاب می‌شود. ابتدا x_1 به‌عنوان مرکز نخستین گروه با پتانسیل P_1 تعیین می‌شود. سپس پتانسیل P_i برای x_i مطابق معادله^۳ (۳) کاهش می‌یابد [6]:

$$P_i = P_i - p_1 e^{(-\beta \|x_i - x_j\|^2)} \quad (3)$$

$$\beta = \frac{4}{r_b^2} \quad (4)$$

که مقدار β از رابطه^۴ (۴) به دست می‌آید و $r_b > 0$ عددی مثبت است که همسایه‌ای را با کاهش قابل توجهی در چگالی تعیین می‌کند. بنابراین، مقدار چگالی نقطه داده‌ای که نزدیک به نخستین خوشه است، به‌طور قابل توجهی کاهش می‌یابد. این رویه (انتخاب مراکز و کاهش پتانسیل) به‌تکرار اجرا شده تا ضوابط و معیارهای توقف تأمین شود. خروجی خوشه‌بندی کاهشی، یک سامانه^۵ استنتاج فازی سوگنو است. یک قانون سوگنو به صورت زیر تعریف می‌شود [6]:


$$\text{Rule1: If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1 x + q_1 y + r_1 \quad (5)$$

که x, y متغیرهای ورودی، A_1, B_1 مجموعه‌های فازی f_1 تابع خروجی را نشان می‌دهد. خروجی نهایی برای یک نمونه در یک سامانه^۶ فازی سوگنو با استفاده از روش میانگین وزن دار که در رابطه^۶ (۶) نشان داده شده است، به دست می‌آید.

¹ Mountain

۳- روش پیشنهادی

بهینه‌سازی، یکی از مهم‌ترین موضوعات در زمینه مهندسی محسوب می‌شود و هدف آن، تنظیم ورودی‌های مسأله و ایجاد نتایج بهینه است. در بسیاری از مسائل، انتخاب بهترین جواب از طریق جستجوی کل فضای مسأله عملی زمان‌بر است؛ بنابراین یک راه‌حل مناسب، استفاده از الگوریتم‌های تکاملی است. بر این اساس در روش پیشنهادی، ابتدا از روش‌های خوشه‌بندی فازی برای تولید یک مدل استنتاج فازی از نوع سوگنو جهت تشخیص خطای نرم‌افزار استفاده و سپس با استفاده از الگوریتم‌های تکاملی مدل‌های به‌دست آمده بهینه می‌شود. این کار از طریق تنظیم پارامترهای مدل‌های فازی انجام خواهد شد. روندنمای روش پیشنهادی در شکل (۱) آمده است. در ادامه به توضیح مراحل مختلف روش پیشنهادی می‌پردازیم.



(شکل-۱): روندنمای روش پیشنهادی
(Figure-1): Flow chart of proposed method

۱. داده‌ها به روش اعتبارسنجی متقابل ده‌تایی^۱ تقسیم شده‌اند. بنابراین اجرای الگوریتم پیشنهادی با رویه ده‌تایی، ده مرتبه تکرار شد. همچنین برای به‌دست‌آوردن نتایج قابل اعتمادتر، رویه پیشنهادی نیز ده مرتبه تکرار شده است.

۲. خوشه‌بندی c میانگین فازی با تعداد خوشه‌های سه اجرا شد. البته در ابتدا با توجه به این که هدف اولیه، خوشه‌بندی مجموعه داده به دو دسته بود، یک دسته برای نمونه‌های طبقه اکثریت و دیگری برای نمونه‌های طبقه اقلیت، تعداد خوشه‌ها دو در نظر گرفته شد؛ اما بعد از چندین سعی و خطا، بهترین نتایج با تعداد خوشه‌های برابر سه به‌دست آمد.

۳. درجه‌های عضویت نمونه‌ها در خوشه‌ها برای اجرای نمونه‌گیری بوت‌استرپ وزن‌دار در مرحله بعد اصلاح شدند. از این‌رو درجه‌های عضویت نمونه‌های اقلیت توسط نرخ عدم توازن افزایش یافتند. این افزایش درجه عضویت بر اساس رابطه زیر صورت می‌گیرد:

$$\mu(x_i) = \mu(x_i) + (IR \times Coef) \quad (11)$$

به‌طوری x_i نمونه‌ای است که به طبقه اقلیت تعلق دارد و IR نرخ عدم توازن که برابر است با نسبت تعداد نمونه‌های طبقه اکثریت به تعداد نمونه‌های کلاس اقلیت. مسأله تشخیص خطا جزو مسائل نامتوازن و تعداد نمونه‌های طبقه اکثریت همواره بسیار بیشتر از تعداد نمونه‌های طبقه اقلیت است؛ بنابراین نرخ عدم توازن مقداری بیشتر از یک خواهد بود. مقدار $Coef$ را در بیشتر مجموعه‌داده‌ها برابر با ۰/۵ در نظر گرفتیم.

¹ 10 fold cross validation

۴. درجه عضویت‌های اصلاح‌شده، به‌عنوان پارامترهای ورودی به الگوریتم نمونه‌گیری بوت‌استرپ داده می‌شوند. اضافه‌کردن وزن ممکن است، باعث افزایش درجه‌های عضویت به مقداری بیش از یک شود؛ بنابراین در الگوریتم بوت‌استرپ، ابتدا درجه‌های عضویت اصلاح‌شده را نرمال می‌کنیم که به مفهوم نگاشت مقادیر بین صفر و یک است؛ سپس احتمال هر درجه عضویت اصلاح‌شده و نرمال‌شده را از طریق رابطه (۱۲) به‌دست می‌آوریم.

$$pr = \frac{\max_{un}}{\sum(\max_{un})} \quad (12)$$

که در آن \max_{un} درجه عضویت اصلاح و نرمال‌شده است؛ سپس احتمال تجمعی را برای احتمالات درجه‌های عضویت، با استفاده از رابطه (۱۳) محاسبه می‌کنیم.

$$Cpr(i) = Cpr(i - 1) + pr(i) \quad (13)$$

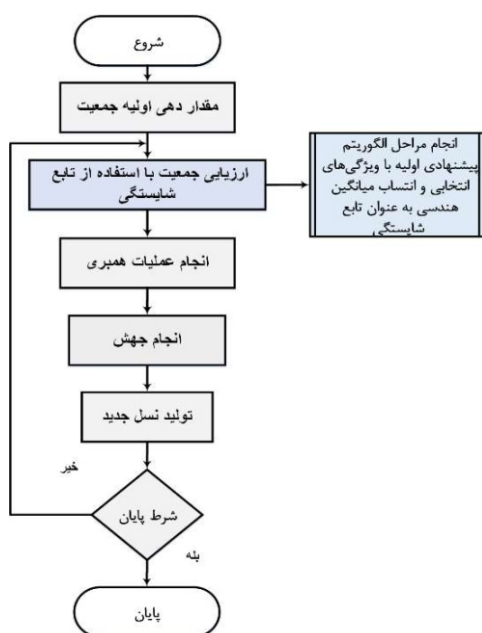
سپس با انتخاب چرخ گردان، اندیس نمونه‌های انتخابی را به‌دست می‌آوریم.

۵. با استفاده از خوشه‌بندی کاهشی و داده‌های آموزشی، طبقه‌بند ساخته می‌شود. این طبقه‌بند در واقع یک سامانه استنتاج سوگنوی فازی است که از تصویرکردن خوشه‌ها روی ابعاد مختلف به‌دست می‌آید. از آنجا که خروجی سامانه‌های سوگنو به‌طور معمول مقدار پیوسته‌ای است،

کردیم. برای به دست آوردن بهترین انتخاب ویژگی در هر مجموعه داده، الگوریتم ژنتیک استفاده شده است. در شکل (۲)، روندنمای الگوریتم ژنتیک استفاده شده آمده و سپس توضیحات بیشتر در مورد آن بیان شده است.

این الگوریتم برای هر ده مجموعه داده به طور جداگانه انجام می شود. طول هر کروموزوم در الگوریتم ژنتیک، به تعداد ویژگی های هر مجموعه داده هست. به ازای هر ویژگی در مجموعه داده، صفر و یک در کروموزوم کد می شود. صفر به معنای انتخاب نشدن ویژگی و یک بدین معناست که ویژگی متناظر آن، انتخاب می شود. در ابتدا به طور تصادفی اعداد صفر و یک در کروموزوم کد می شود؛ سپس الگوریتم پیشنهادی اولیه با ویژگی های انتخاب شده در کروموزوم، اجرا می شود. هر بار اجرا، شایستگی افراد جمعیت محاسبه می شود. همان طور که در شکل (۲) نشان داده شده است، برای محاسبه شایستگی افراد جمعیت، الگوریتم پیشنهادی اولیه دومرتبه اجرا که در هر مرتبه از روش اعتبارسنجی متقابل ده تایی استفاده و سپس میانگین مقادیر میانگین هندسی برای محاسبه تابع شایستگی برگردانده می شود. تابع شایستگی طبق رابطه (۱۹) در نظر گرفته شده است که باید کمینه شود. این بدان معناست که مقدار میانگین هندسی باید بیشینه شود.

$$Fitness = 1 - Gmean \quad (19)$$



(شکل-۲): روندنمای الگوریتم ژنتیک استفاده شده در این مقاله (Figure -2): Flow chart of genetic algorithm used in this paper

در جدول (۱) پارامترهای الگوریتم ژنتیک استفاده شده آورده شده است.

به منظور گسسته سازی خروجی از تابع جزء صحیح استفاده می کنیم. همچنین می توان از تابع سیگموئید^۱ جهت مقیاس کردن خروجی سامانه فازی بین صفر و یک استفاده کرد و بدین ترتیب از سامانه سوگنوی فازی به عنوان یک طبقه بند استفاده کرد.

تعداد قوانین در سامانه سوگنوی فازی تولید شده توسط خوشه بندی کاهشی به شعاع خوشه بندی وابسته است. مقادیر شعاع بزرگ باعث تولید قوانین کمتر و مقادیر کوچک، باعث تولید قوانین بیشتر می شود. در این مقاله برای هر قانون، دو خروجی به صورت زیر در نظر گرفته شده است. دلیل این کار، راحت بودن در استفاده از ماتریس گجی بوده است.

If x_1 is A_1 and x_2 is B_1 then $y_1^{(1)} = 0.2x_1 - 0.3x_2 - 1$ and $y_2^{(1)} = 0.3x_1 + 0.4x_2 - 2$.

If x_1 is A_2 and x_2 is B_2 then $y_1^{(2)} = 5x_1 - 3x_2 + 4$ and $y_2^{(2)} = 4x_1 + 5x_2 - 5$.

$$W_1 = \mu_{A_1}(x_1) \cdot \mu_{B_1}(x_2) \quad W_2 = \mu_{A_2}(x_1) \cdot \mu_{B_2}(x_2)$$

$$Y_1^{Total} = \frac{W_1 y_1^{(1)} + W_2 y_1^{(2)}}{W_1 + W_2}$$

$$Y_2^{Total} = \frac{W_1 y_2^{(1)} + W_2 y_2^{(2)}}{W_1 + W_2}$$

در نهایت طبقه خروجی با استفاده از دو مقدار Y_1^{Total} و Y_2^{Total} به صورت زیر تعیین می شود:

$$Out_1 = \text{sigmoid}(Y_1^{Total}) \quad (14)$$

$$Out_2 = \text{sigmoid}(Y_2^{Total}) \quad (15)$$

مقادیر $[Out_1, Out_2]$ در کنار یکدیگر طبقه پیشنهادی را تعیین می کنند. اگر این مقادیر $[1,0]$ باشند، طبقه نخست و اگر $[0,1]$ باشند، طبقه دوم را تعیین می کنند. ۶. در آخرین مرحله، مقادیر معیارهای کارایی برای روش پیشنهادی طبق روابط زیر محاسبه می شود [1]:

$$G - mean = \sqrt{Tpr \cdot Tnr} \quad (16)$$

$$AUC = \frac{1 + Tpr - Fpr}{2} \quad (17)$$

$$Balance = 1 - \frac{\sqrt{(1 - Tnr)^2 + (1 - Tpr)^2}}{\sqrt{2}} \quad (18)$$

در الگوریتم پیشنهادی اولیه از تمام ویژگی های مجموعه داده ها، استفاده کردیم. برای بهبود این روش و در نتیجه به دست آوردن نتایج بهتر، به جای استفاده از تمام ویژگی های مجموعه داده ها، مهم ترین ویژگی ها را انتخاب

^۱ Sigmoid

(جدول-۱): پارامترهای الگوریتم ژنتیک

(Table-1): Parameters of Genetic algorithm

مقدار	پارامتر الگوریتم ژنتیک
۱۰۰	اندازه جمعیت
۱۰۰	تعداد نسل (تعداد تکرار)
۱	طول ژن
۰/۷	احتمال همبندی
۰/۱	احتمال جهش

می‌کنیم. برای تحلیل نتایج گزارش شده در این مقاله، از آزمون تی^۹ با دو نمونه مستقل که جزو مدل‌های آماری پارامتریک است، استفاده و همچنین برای ارزیابی کارایی روش‌ها و نشان دادن عملی بودن نتایج ارائه شده در این پژوهش، از سه معیار تعادل، سطح زیر نمودار و میانگین هندسی استفاده کرده‌ایم. این معیارها روی توزیع طبقه داده‌ها حساس هستند و بنابراین برای مسئله تشخیص خطا مناسب هستند. هر چه مقدار این سه معیار بیشتر باشد، پیش‌بینی‌کننده عملکرد بهتری دارد.

(جدول-۲): مجموعه داده‌های پرومیس استفاده شده

در ساخت مدل‌های پیش‌بینی

(Table-2): PROMISE dataset utilized in obtaining proposed models

مجموعه داده	زبان برنامه‌نویسی	تعداد نمونه	تعداد ویژگی	% خطا
mc2	C++	۱۶۱	۳۹	۳۲/۲۹
kc2	C++	۵۲۲	۲۱	۲۰/۴۹
jm1	C	۱۰۸۸۵	۲۱	۱۹/۳۵
kc1	C++	۲۱۰۹	۲۱	۱۵/۴۵
pc4	C	۱۴۵۸	۳۷	۱۲/۲۰
pc3	C	۱۵۶۳	۳۷	۱۰/۲۳
cm1	C	۴۹۸	۲۱	۹/۸۳
kc3	Java	۴۵۸	۳۹	۹/۳۸
mw1	C	۴۰۳	۳۷	۷/۶۹
pc1	C	۱۱۰۹	۲۱	۶/۹۴

جدول‌های ۳، ۴ و ۵ نشان‌گر میانگین و انحراف معیار معیارهای میانگین هندسی، تعادل و سطح زیر نمودار است که توسط روش یادگیری بر روی ده مجموعه داده به دست آمده‌اند. نتایج مربوط به هشت روش یادگیری غیر از روش پیشنهادی از مرجع [1] آورده شده است. هر عدد در جدول، میانگین صد اجرای مستقل است. مقادیر پررنگ شده در هر سطر بیان‌گر این مسئله هستند که از بقیه موارد به‌طور معنادار بهتر هستند. تفاوت معناداری میان چند مقدار پررنگ شده در یک سطر، وجود ندارد. جداول ۶، ۷ و ۸ نشان‌دهنده برد، باخت یا مساوی بودن نتایج روش پیشنهادی با هشت روش متداول دیگر به ترتیب در معیارهای میانگین هندسی، تعادل و سطح زیر نمودار هستند. در این جداول حروف L، W و T به ترتیب بیان‌گر برد، باخت و مساوی بودن نتیجه هستند. از مشاهده این جداول متوجه می‌شویم که روش پیشنهادی بهترین نتیجه را در معیارهای میانگین هندسی و تعادل، در شش مجموعه داده از ده مجموعه داده به دست آورد. برای داده‌هایی که نرخ عدم توازن زیادی دارند، مثل مجموعه داده‌های cm1، kc3، mw1 و pc1، روش پیشنهادی در معیارهای میانگین هندسی و تعادل عملکرد بسیار خوبی دارد.

۴- نتایج و بحث

در این بخش، کارایی الگوریتم پیشنهادی خود را با هشت الگوریتم متداول در مسئله تشخیص خطا مقایسه می‌کنیم و سپس به تحلیل نتایج می‌پردازیم. هشت الگوریتم پرکاربرد یادگیری طبقه‌های نامتوازن عبارتند از: الگوریتم کاهش طبقه اکثریت به‌طور تصادفی^۱، الگوریتم کاهش اکثریت به‌طور تصادفی^۲، الگوریتم مبتنی بر حرکت حد آستانه^۳، الگوریتم اسموت ارتقایافته^۴، الگوریتم آدابوست ان سی^۵، الگوریتم بیز ساده با لاگ فیلتر^۶، الگوریتم جنگل تصادفی^۷، الگوریتم آدابوست ان سی پویا^۸. مشخصات مجموعه داده‌هایی که در ساخت مدل‌های پیشنهادی استفاده شده‌اند، در جدول (۲) فهرست شده است [1]. این مجموعه داده‌ها در انبار داده پرومیس در دسترس هستند و به ترتیب نرخ عدم توازن در جدول قرار گرفته‌اند. به‌عنوان مثال، مجموعه داده mc2 دارای ۱۶۱ نمونه و مجموعه داده jm1 دارای ۱۰۸۸۵ نمونه است. همچنین درصد نمونه‌های خطا از ۳۲/۲۹ درصد تا ۶/۹۴ درصد متغیر است.

در این مقاله برای اطمینان از وجود تفاوتی معنی‌دار میان روش‌ها از آزمون‌های آماری استفاده شده است [21] منظور از تفاوت معنی‌دار میان روش‌ها این است که اختلاف میان روش‌ها به حد کافی بزرگ باشد تا بتوان اطمینان حاصل کرد که نتایج به‌طور تصادفی یا بر اثر شانس، بهتر نشده‌اند. انتخاب آزمون آماری مناسب، بستگی به تعداد متغیرهای پژوهش، تعداد گروه‌های مقایسه شده، مستقل یا وابسته بودن گروه‌ها، نرمال بودن یا نبودن توزیع داده‌ها و نوع داده‌ها (عددی، رتبه‌ای، اسمی) دارد. اگر نوع داده‌ها کمی و توزیع آن‌ها نرمال باشد از مدل‌های آماری پارامتریک استفاده

¹ Random undersampling (RUS)² Balanced random undersampling (RUS-bal)³ Threshold-moving (THM)⁴ SMOTEBoost (SMB)⁵ AdaBoost.NC (BNC)⁶ Naive Bayes with the log filter (NB)⁷ Random Forest (RF)⁸ Dynamic AdaBoost.NC (DNC)⁹ T-Test

در مقایسه روش پیشنهادی با هشت روش متداول دیگر، در مجموع، روی ده مجموعه داده، تعداد ۶۷ مرتبه در معیار میانگین هندسی، به طور معنادار نتیجه‌ای بهتر از نتایج روش‌های دیگر به دست آورده است. همچنین در هفت مورد، نتیجه مساوی و تنها در شش مورد، نتیجه بدتری داشته است. به عبارت دیگر الگوریتم پیشنهادی در تمامی مجموعه داده‌ها، در معیار میانگین هندسی، از روش‌های حرکت حد آستانه، اسموت ارتقایافته و جنگل تصادفی عملکرد بهتری دارد. در پنج مورد به طور معنادار نتیجه‌ای مساوی با روش‌های کاهش طبقه اکثریت به طور تصادفی و کاهش طبقه اکثریت به طور تصادفی و متعادل و بیز ساده به دست آمده است. در مجموعه داده‌های pc3 و pc4 از روش‌های آدابوست ان سی و آدابوست ان سی پویا مقدار میانگین هندسی کمتری به دست آورد. با توجه به نتایج به دست آمده درمی‌یابیم که روش پیشنهاد شده در پیش‌بینی درست نمونه‌های طبقه خطادار و بدون خطا، قابلیت زیادی دارد و دارای دقت بالا در هر دو طبقه است. چون مقدار معیار میانگین هندسی، نرخ تشخیص درست را بازتاب می‌کند.

معیار سطح زیر نمودار میزان تعادل در نرخ تشخیص درست و نرخ تشخیص اشتباه را نشان می‌دهد. از مجموع هشتاد مقایسه انجام شده بر روی ده مجموعه داده در معیار سطح زیر نمودار راک، روش پیشنهادی در ۳۴ مرتبه نسبت به دیگر روش‌ها، به طور معناداری به نتایج بهتری دست پیدا کرده است. همچنین با سیزده نتیجه روش‌های متداول دیگر، بنابر آزمون تی، از لحاظ مفهومی برابر است. بنابراین می‌توان گفت در مجموع از هشتاد مقایسه انجام شده، در ۴۷ مورد نتیجه‌ای بهتر یا مساوی با دیگر روش‌های متداول تشخیص خطا به دست آورده است. تنها در ۳۳ مورد، عملکرد خوبی نداشته است. در معیار سطح زیر نمودار راک، روش پیشنهادی از روش‌های کاهش طبقه اکثریت به طور تصادفی، کاهش طبقه اکثریت به طور تصادفی و متعادل و حرکت حد آستانه، در نه مجموعه داده بهتر عمل کرده و نسبت به بقیه روش‌ها عملکرد خوبی نداشته است.

معیار تعادل، فاصله اقلیدسی بین ایده‌آل‌ترین نقطه را (آنجا که نرخ تشخیص خطا یک و نرخ عدم تشخیص خطا صفر است) در نمودار راک و موقعیت واقعی نشان می‌دهد. مقدار این معیار بین صفر و یک متغیر است. اگر مقدار آن برابر با یک باشد، به معنای این است که تمام خطاها بدون اشتباه تشخیص داده شده‌اند. از مشاهده جداول ۳، ۴، ۵ درمی‌یابیم که در شش مجموعه داده از ده مجموعه داده، روش پیشنهادی نسبت به هشت روش متداول دیگر، به نتایج بهتری در معیار تعادل دست پیدا کرده است. روش آدابوست ان سی پویا در

چهار مورد و روش آدابوست ان سی در دو مورد عملکردهای بهتری نسبت به روش پیشنهاد شده داشتند. بقیه روش‌ها در هر ده مجموعه داده به طور معنادار، نسبت به روش پیشنهادی عملکرد ضعیف‌تری داشتند. بنابراین روش پیشنهاد شده در معیار تعادل تعداد ۶۸ برد، ۴ مساوی و هشت باخت از مجموع هشتاد مقایسه انجام شده به دست آورد که این نتایج نشان‌دهنده پیش‌بینی درست خطاها با دقت به نسبت خوب، توسط روش پیشنهادی است. به طور کلی از مشاهده جداول درمی‌یابیم که برای داده‌هایی با نرخ عدم توازن بالا، روش پیشنهادی انتخاب خوبی است. به طور کلی روش‌های آدابوست ان سی، آدابوست ان سی پویا و روش پیشنهادی کارایی بهتری نسبت به روش‌های کاهش کلاس اکثریت به طور تصادفی، کاهش طبقه اکثریت به طور تصادفی و متعادل، حرکت حد آستانه، اسموت ارتقایافته، بیز ساده و جنگل تصادفی دارند.

شکل (۳) نمودار میله‌ای میانگین مقادیر معیارهای کارایی میانگین هندسی، سطح زیر نمودار و تعادل همراه با مقادیر انحراف معیار را بر روی ده مجموعه داده خطای نرم‌افزار نشان می‌دهد. این مقادیر توسط هشت روش متداول در زمینه یادگیری مسائل نامتوازن و یک روش پیشنهاد شده به دست آمده است که محور افقی نمودار را تشکیل می‌دهند. محور عمودی این نمودار نشان‌گر میانگین مقادیر سه معیار کارایی بر روی ده مجموعه داده است. همان‌طور که در نمودار میله‌ای مشاهده می‌شود، ارتفاع مقادیر معیارهای کارایی میانگین هندسی و تعادل در روش پیشنهادی از تمام روش‌های متداول دیگر بالاتر است. این نتیجه به معنای آن است که روش پیشنهادی نسبت به روش‌های دیگر، در پیش‌بینی نمونه‌های هر دو طبقه از دقت بالاتری برخوردار است. چون معیار میانگین هندسی نشان‌دهنده تشخیص درست طبقه‌های مثبت و منفی و معیار تعادل، بیان‌گر کارایی پیش‌بینی‌کننده در ایجاد تعادل میان نرخ تشخیص درست و نرخ عدم تشخیص درست است. ارتفاع معیار سطح زیر نمودار در روش جنگل تصادفی از همه روش‌ها بیشتر است، اما میانگین مقادیر معیارهای تعادل و میانگین هندسی آن از همه روش‌ها کمتر است. بنابراین، این روش دقت کافی برای پیش‌بینی طبقه‌های مثبت و منفی ندارد و روش مناسبی برای حل مسئله تشخیص خطای نرم‌افزار نیست. به طور کلی از مشاهده نمودار میله‌ای نتیجه می‌گیریم که روش پیشنهادی و روش‌های آدابوست ان سی و آدابوست ان سی پویا، کارایی بهتری نسبت به روش‌های کاهش طبقه اکثریت به طور تصادفی، کاهش طبقه اکثریت به طور تصادفی و متعادل، حرکت حد آستانه، اسموت ارتقایافته، بیز ساده و جنگل تصادفی دارند و برای مسئله خطای نرم‌افزار مناسب هستند.

(جدول-۳): مقایسه میانگین و انحراف معیار روش پیشنهادی با سایر روش‌ها برای معیار میانگین هندسی
 (Table-3): comparing the mean and standard deviation of proposed method with the others for G-mean measure

G-mean	RUS	RUS-bal	THM	SMB	BNC	NB	RF	DNC	Proposed method
mc2	0.571±0.150	0.578±0.140	0.566±0.173	0.627±0.169	0.597±0.135	0.6070.137	0.5350.191	0.571±0.152	0.682±0.120
kc2	0.720±0.081	0.720±0.080	0.675±0.120	0.642±0.108	0.762±0.083	0.734±0.070	0.6470.105	0.777±0.701	0.759±0.081
jm1	0.649±0.022	0.645±0.018	0.647±0.019	0.541±0.025	0.679±0.016	0.594±0.020	0.494±0.025	0.672±0.017	0.692±0.073
kc1	0.670±0.071	0.686±0.050	0.643±0.064	0.582±0.072	0.723±0.046	0.694±0.031	0.562±0.072	0.734±0.040	0.7190.043
pc4	0.799±0.076	0.816±0.053	0.747±0.097	0.723±0.077	0.865±0.048	0.780±0.036	0.638±0.089	0.734±0.040	0.8050.037
pc3	0.669±0.095	0.690±0.057	0.588±0.110	0.504±0.099	0.757±0.073	0.680±0.039	0.423±0.122	0.859±0.047	0.689±0.072
em1	0.485±0.254	0.584±0.143	0.452±0.250	0.301±0.257	0.597±0.216	0.681±0.084	0.152±0.225	0.745±0.061	0.730±0.097
kc3	0.563±0.247	0.682±0.123	0.430±0.268	0.433±0.262	0.665±0.175	0.724±0.082	0.225±0.265	0.659±0.133	0.743±0.155
mw1	0.540±0.253	0.631±0.160	0.336±0.315	0.388±0.304	0.525±0.306	0.637±0.191	0.334±0.313	0.647±0.272	0.729±0.154
pc1	0.645±0.157	0.711±0.089	0.601±0.195	0.553±0.191	0.691±0.130	0.576±0.050	0.505±0.167	0.698±0.145	0.730±0.102

(جدول ۴-): مقایسه میانگین و انحراف معیار روش پیشنهادی با سایر روش‌ها برای معیار تعادل.
 (Table-4): comparing the mean and standard deviation of proposed method with the others for Balance

balance	RUS	RUS-bal	THM	SMB	BNC	NB	RF	DNC	Proposed method
Mc2	0.571±0.125	0.574±0.122	0.570±0.135	0.620±0.146	0.588±0.128	0.595±0.128	0.538±0.130	0.569±0.134	0.665±0.113
Kc2	0.705±0.086	0.709±0.078	0.660±0.117	0.68±0.0101	0.753±0.084	0.719±0.062	0.617±0.101	0.777±0.071	0.720±0.097
Jm1	0.646±0.023	0.642±0.001 9	0.643±0.0 20	0.518±0.021	0.678±0.017	0.584±0.020	0.474±0.019	0.672±0.027	0.688±0.513
Kc1	0.659±0.073	0.677±0.052	0.627±0.067	0.551±0.063	0.718±0.050	0.663±0.026	0.529±0.060	0.733±0.042	0.716±0.042
Pc4	0.784±0.086	0.808±0.050	0.721±0.104	0.682±0.080	0.854±0.049	0.753±0.031	0.593±0.083	0.850±0.043	0.789±0.032
Pc3	0.659±0.093	0.683±0.052	0.571±0.100	0.478±0.071	0.749±0.078	0.651±0.031	0.432±0.064	0.739±0.064	0.663±0.083
Cm1	0.526±0.146	0.577±0.112	0.502±0.145	0.407±0.122	0.607±0.118	0.663±0.284	0.345±0.225	0.653±0.117	0.719±0.091
Kc3	0.581±0.164	0.669±0.114	0.483±0.151	0.472±0.132	0.655±0.144	0.693±0.129	0.389±0.110	0.655±0.143	0.733±0.123
Mw1	0.566±0.161	0.619±0.126	0.450±0.165	0.470±0.159	0.567±0.193	0.636±0.137	0.444±0.157	0.623±0.177	0.717±0.136
Pc1	0.636±0.085	0.688±0.078	0.596±0.149	0.541±0.128	0.665±0.126	0.553±0.037	0.496±0.108	0.682±0.133	0.722±0.099
pc1	0.645±0.157	0.711±0.089	0.601±0.195	0.553±0.191	0.691±0.130	0.576±0.050	0.505±0.167	0.698±0.145	0.730±0.102

(جدول-۵): مقایسه میانگین و انحراف معیار روش پیشنهادی با سایر روش‌ها
برای معیار سطح زیر نمودار.

(Table-5): comparing the mean and standard deviation of proposed method with the others for AUC

AUC	RUS	RUS-bal	THM	SMB	BNC	NB	RF	DNC	Proposed method
mc2	0.615±0.133	0.623±0.135	0.639±0.116	0.750±0.128	0.690±0.130	0.700±0.150	0.722±0.118	0.649±0.142	0.702±0.107
kc2	0.730±0.087	0.726±0.092	0.687±0.092	0.742±0.092	0.803±0.085	0.820±0.071	0.823±0.077	0.828±0.074	0.768±0.072
jm1	0.665±0.023	0.658±0.020	0.661±0.024	0.691±0.017	0.733±0.017	0.679±0.019	0.748±0.019	0.766±0.016	0.701±0.027
kc1	0.710±0.063	0.713±0.059	0.670±0.058	0.755±0.046	0.802±0.033	0.758±0.038	0.802±0.033	0.818±0.034	0.721±0.04 ³
pc4	0.823±0.069	0.827±0.063	0.791±0.068	0.923±0.023	0.938±0.025	0.863±0.035	0.937±0.019	0.917±0.031	0.810±0.038
pc3	0.689±0.087	0.694±0.073	0.664±0.071	0.813±0.052	0.836±0.050	0.777±0.054	0.848±0.045	0.816±0.056	0.717±0.057
cm1	0.622±0.126	0.622±0.129	0.595±0.139	0.704±0.112	0.785±0.080	0.748±0.091	0.742±0.105	0.787±0.097	0.738±0.090
kc3	0.643±0.183	0.686±0.157	0.590±0.151	0.740±0.133	0.806±0.104	0.8150.082	0.827±0.105	0.797±0.102	0.761±0.116
mw1	0.647±0.145	0.681±0.131	0.584±0.142	0.758±0.145	0.777±0.137	0.780±0.142	0.756±0.138	0.714±0.139	0.749±0.125
Pc1	0.726±0.129	0.739±0.098	0.735±0.116	0.851±0.80	0.871±0.057	0.700±0.096	0.847±0.067	0.866±0.081	0.740±0.089

(جدول ۶-): نتایج مقایسه بر اساس t-test به صورت برد، مساوی یا باخت برای معیار میانگین هندسی.

(Table-6): comparing results of T-test as Win, Tie or Lost for G-mean

G-mean	RUS	RUS-bal	THM	SMB	BNC	NB	RF	DNC
mc2	W	W	W	W	W	W	W	W
kc2	W	W	W	W	T	W	W	L
jm1	W	W	W	W	W	W	W	W
kc1	W	W	W	W	T	W	W	L
pc4	T	T	W	W	L	W	W	L
pc3	W	T	W	W	L	T	W	L
cm1	W	W	W	W	W	W	W	W
kc3	W	W	W	W	W	W	W	W
mw1	W	W	W	W	W	W	W	W
pc1	W	T	W	W	W	W	W	W
Total Wins = 67 Total losses = 6 Total Ties = 7								

(جدول ۷-): نتایج مقایسه بر اساس آزمون تی به صورت برد، مساوی یا باخت برای معیار تعادل.


(Table-7): comparing results of T-test as Win, Tie or Lost for Balance

Balance	RUS	RUS-bal	THM	SMB	BNC	NB	RF	DNC
mc2	W	W	W	W	W	W	W	W
kc2	W	W	W	W	L	T	W	L
jm1	W	W	W	W	W	W	W	W
kc1	W	W	W	W	T	W	W	L
pc4	T	L	W	W	L	W	W	L
pc3	W	T	W	W	L	W	W	L
cm1	W	W	W	W	W	W	W	W
kc3	W	W	W	W	W	W	W	W
mw1	W	W	W	W	W	W	W	W
pc1	W	W	W	W	W	W	W	W
Total Wins = 68 Total losses = 8 Total Ties = 4								

(جدول ۸-): نتایج مقایسه بر اساس آزمون تی به صورت برد، مساوی یا باخت برای معیار سطح زیر نمودار.

(Table-8): comparing results of T-test as Win, Tie or Lost for AUC

AUC	RUS	RUS-bal	THM	SMB	BNC	NB	RF	DNC
mc2	W	W	W	L	W	T	T	W
kc2	W	W	W	W	T	L	L	L
jm1	W	W	W	W	L	W	L	L
kc1	W	W	W	L	L	L	L	L
pc4	T	L	W	L	L	L	L	L
pc3	W	W	W	L	L	L	L	L
cm1	W	W	W	W	L	T	T	L
kc3	W	W	W	T	L	L	L	L
mw1	W	W	W	T	T	T	T	W
pc1	W	T	T	L	L	W	L	L
Total Wins = 34 Total losses = 33 Total Ties = 13								



(شکل ۳-): مقایسه کارایی روش پیشنهادی با بقیه روشها با نمودار میله‌ای: میانگین مقادیر معیارهای کارایی میانگین هندسی، سطح زیر نمودار و تعادل، همراه با مقادیر انحراف معیار آنها بر روی ده مجموعه داده خطای نرم افزار.

(Figure-3): performance comparison of our proposed method with the others by bar chart: the mean of G-mean, AUC and balance values as well as their standard deviation for ten datasets.

تشخیص ماژول‌های مستعد خطا در ابتدای پروژه‌های نرم‌افزاری، باعث صرفه‌جویی در تلاش و هزینه‌های گروه توسعه می‌شود. این ماژول‌ها درصد کمی از سامانه نرم‌افزاری را شامل می‌شوند؛ بنابراین مسئله تشخیص خطا جزو مسائل نامتوازن است و تشخیص ماژول‌های مستعد خطا نسبت به ماژول‌های بدون خطا اهمیت بیشتری دارد.

در این مقاله با استفاده از خوشه‌بندی کاهشی و خوشه‌بندی فازی C میانگین فازی یک مدل پیش‌بینی خطای نرم‌افزار تولید و بدین منظور در ابتدا از تمام ویژگی‌های نمونه‌ها در مجموعه داده‌ها استفاده کردیم؛ اما با توجه به این که ممکن است در هر مجموعه داده بعضی از ویژگی‌ها از بقیه مهم‌تر باشند، برای بهبود نتایج به‌دست آمده از الگوریتم ژنتیک برای انتخاب ویژگی استفاده کردیم. برای کنترل و حل نامتوازن بودن طبقه‌ها، نمونه‌های طبقه اقلیت را وزن‌دار کردیم تا طبقه‌بند به طبقه اقلیت توجه بیشتری کند.

نتایج به‌دست آمده از روش پیشنهادی با هشت الگوریتم متداول مقایسه و ارزیابی شده‌اند. این الگوریتم‌ها شامل سه نوع روش یادگیری جمعی، نمونه‌گیری مجدد و حرکت حد آستانه می‌شوند. این ارزیابی بر روی ده مجموعه داده خطای نرم‌افزار که گستره وسیعی از اندازه و نرخ عدم توازن را در بردارند، انجام شد. برای نشان دادن این که نتایج به‌دست آمده در عمل مفید هستند، از سه معیار ارزیابی کارایی استفاده کردیم. این معیارها شامل میانگین هندسی، تعادل و معیار سطح زیرنمودار هستند. نتایج مقایسه‌ها نشان دادند که الگوریتم پیشنهادی بهترین نتایج را در معیارهای میانگین هندسی و تعادل به‌دست آورد. الگوریتم جنگل تصادفی مقدار معیار سطح زیر نمودار بالا و مقدار معیارهای تعادل و میانگین هندسی بسیار کمی به‌دست آورد. بنابراین این الگوریتم برای مسئله تشخیص خطای نرم‌افزار مناسب نیست. بالابودن مقدار سطح زیرنمودار در الگوریتم آدابوست ان سی پویا نسبت به روش پیشنهادی و کم‌تر بودن مقادیر میانگین هندسی و تعادل نشان‌دهنده این است که مقادیر نرخ تشخیص درست هر دو طبقه، نسبت به روش پیشنهادی اختلاف بیشتری دارند؛ درحالی که در روش پیشنهادی ما، این مقادیر هر دو بالا و به هم نزدیک هستند. علاوه بر معیارهای دقت، از دیگر مزایای الگوریتم پیشنهادی می‌توان به مواردی چون وابسته نبودن زیاد به پارامترها، زمان محاسباتی به‌نسبه کم، پیچیده نبودن طبقه‌بندی‌های به‌دست آمده و ساخت طبقه‌بند قدرتمند با

استفاده از منطق فازی و الگوریتم‌های تکاملی اشاره کرد. روش پیشنهادی باوجود آن که در معیارهای میانگین هندسی و تعادل نتایج بسیار خوبی به‌دست آورده است، اما در معیار سطح زیرنمودار نتایج چندان رضایت‌بخش نیست. علت این است که روش پیشنهادی روی داده‌های با نرخ عدم توازن بالا، خوب عمل می‌کند و روی داده‌های با نرخ عدم توازن پایین، به‌خوبی روش آدابوست ان سی پویا نیست.

6- References

۶-مراجع

- [1] S. Wang and X. Yao, "Using class imbalance learning for software defect prediction," *IEEE Trans. Reliab.*, vol. 62, no. 2, pp. 434-443, 2013.
- [2] B.-J. Park, S.-K. Oh, and W. Pedrycz, "The design of polynomial function-based neural network predictors for detection of software defects," *Inf. Sci. (Ny)*, vol. 229, pp. 40-57, 2013.
- [3] P. C. Pendharkar, "Exhaustive and heuristic search approaches for learning a software defect prediction model," *Eng. Appl. Artif. Intell.*, vol. 23, no. 1, pp. 34-40, 2010.
- [4] J. Zheng, "Cost-sensitive boosting neural networks for software defect prediction," *Expert Syst. Appl.*, vol. 37, no. 6, pp. 4537-4543, 2010.
- [5] مهدی زاده محبوبه، افتخاری مهدی. ارائه روش جدید مبتنی بر برنامه‌نویسی ژنتیک برای وزن‌دهی قوانین فازی در طبقه‌بندی نامتوازن. پردازش علائم و داده‌ها. ۱۳۹۳؛ ۱۱ (۲): ۱۱۱-۱۲۵
- [6] Mahdizadeh Mahboubeh, Eftekhari Mahdi. "A new fuzzy rules weighting approach based on Genetic Programming for imbalanced classification". *JSDP.*, no. 11 (2), pp.111-125, 2015
- [7] Z. Yan, X. Chen, and P. Guo, "Software defect prediction using fuzzy support vector regression," *Adv. Neural Networks-ISNN 2010*, pp. 17-24, 2010.
- [8] A. K. Pandey and N. K. Goyal, "A fuzzy model for early software fault prediction using process maturity and software metrics," *Int. J. Electron. Eng.*, vol. 1, no. 2, pp. 239-245, 2009.
- [9] S. Di Martino, F. Ferrucci, C. Gravino, and F. Sarro, "A genetic algorithm to configure support vector machines for predicting fault-prone components," in *International Conference on Product Focused Software Process Improvement*, 2011, pp. 247-261.
- [10] P. S. Sandhu, S. Khullar, S. Singh, S. K. Bains, M. Kaur, and G. Singh, "A Study on Early Prediction of Fault Proneness in Software Modules using Genetic Algorithm," *World Acad. Sci. Eng. Technol.*, vol. 72, 2010.



مهدی افتخاری مدرک کارشناسی خود را در سال ۱۳۷۹ در رشته مهندسی کامپیوتر گرایش سخت‌افزار از دانشگاه شیراز و مدارک کارشناسی ارشد و دکترای خود را به ترتیب در سال‌های

۱۳۸۲ و ۱۳۸۶ در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از همان دانشگاه اخذ کرد. وی از سال ۱۳۸۶ تا کنون عضو هیأت علمی بخش مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان است و در سال ۱۳۹۳ به مرتبه دانشیاری ارتقا پیدا کرده است. حوزه‌های تخصصی ایشان مجموعه‌ها و مدل‌های فازی، الگوریتم‌های تکاملی و یادگیری ماشین است. وی تاکنون بیش از ۱۲۰ مقاله علمی در نشریات و کنفرانس‌های معتبر داخلی و خارجی به چاپ رسانیده است.

نشانی رایانامه ایشان عبارت است از:

m.eftekhari@uk.ac.ir



مریم مجیدی مؤمن‌آبادی مدرک کارشناسی خود را در سال ۱۳۸۹ در رشته مهندسی کامپیوتر گرایش نرم‌افزار از دانشگاه شهید باهنر کرمان و مدرک کارشناسی ارشد خود را در سال ۱۳۹۳ در

رشته مهندسی فناوری اطلاعات گرایش طراحی و تولید نرم‌افزار دانشگاه آزاد اسلامی واحد کرمان اخذ کرد. حوزه‌های تخصصی ایشان مجموعه‌ها و مدل‌های فازی، طراحی نرم‌افزار و توسعه نرم‌افزار برای تلفن‌های همراه است.

نشانی رایانامه ایشان عبارت است از:

Maryam.majidi93@gmail.com



مجتبی خمر مدرک کارشناسی خود را در سال ۱۳۹۳ در رشته مهندسی کامپیوتر گرایش سخت‌افزار از دانشگاه سیستان و بلوچستان و مدرک کارشناسی ارشد خود را در سال ۱۳۹۶ در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه شهید باهنر کرمان اخذ کرد. حوزه‌های تخصصی ایشان مجموعه‌ها و مدل‌های فازی، و یادگیری ماشین است.

نشانی رایانامه ایشان عبارت است از:

Mojtabakhammar69@gmail.com

- [10] M. M. Rosli, N. H. I. Teo, N. S. M. Yusop, and N. S. Mohammad, "The design of a software fault prone application using evolutionary algorithm," in *Open Systems (ICOS), 2011 IEEE Conference on*, 2011, pp. 338–343.
- [11] M.-Y. Chen, "A hybrid ANFIS model for business failure prediction utilizing particle swarm optimization and subtractive clustering," *Inf. Sci. (Ny)*, vol. 220, pp. 180–195, 2013.
- [12] M. E. R. Bezerra, A. L. I. Oliveira, and S. R. L. Meira, "A constructive rbf neural network for estimating the probability of defects in software modules," in *Neural Networks, 2007. IJCNN 2007. International Joint Conference on*, 2007, pp. 2869–2874.
- [13] M. E. R. Bezerra, A. L. I. Oliveiray, and P. J. L. Adeodatoz, "Predicting software defects: A cost-sensitive approach," in *Systems, Man, and Cybernetics (SMC), 2011 IEEE International Conference on*, 2011, pp. 2515–2522.
- [14] H. A. Al-Jamimi and L. Ghouti, "Efficient prediction of software fault proneness modules using support vector machines and probabilistic neural networks," in *Software Engineering (MySEC), 2011 5th Malaysian Conference in*, 2011, pp. 251–256.
- [15] N. R. Pal, K. Pal, J. M. Keller, and J. C. Bezdek, "A possibilistic fuzzy c-means clustering algorithm," *IEEE Trans. fuzzy Syst.*, vol. 13, no. 4, pp. 517–530, 2005.
- [16] D. Gray, D. Bowes, N. Davey, Y. Sun, and B. Christianson, "Using the Support Vector Machine as a Classification Method for Software Defect Prediction with Static Code Metrics.," in *EANN*, 2009, vol. 2009, pp. 223–234.
- [17] K. O. Elish and M. O. Elish, "Predicting defect-prone software modules using support vector machines," *J. Syst. Softw.*, vol. 81, no. 5, pp. 649–660, 2008.
- [18] S. Wang, A. Mathew, Y. Chen, L. Xi, L. Ma, and J. Lee, "Empirical analysis of support vector machine ensemble classifiers," *Expert Syst. Appl.*, vol. 36, no. 3, pp. 6466–6476, 2009.
- [19] I. Gondra, "Applying machine learning to software fault-proneness prediction," *J. Syst. Softw.*, vol. 81, no. 2, pp. 186–195, 2008.
- [20] S. R. Kannan, S. Ramathilagam, and P. C. Chung, "Effective fuzzy c-means clustering algorithms for data clustering problems," *Expert Syst. Appl.*, vol. 39, no. 7, pp. 6292–6300, 2012.
- [21] O. T. Yildiz, O. Aslan, and E. Alpaydin, "Multivariate statistical tests for comparing classification algorithms," *Lect Notes Comp Sci*, vol. 6683, pp. 1–15, 2011.