ارائه یک روش نوین جهت پیش‌بینی نقص نرم‌افزار با استفاده از ترکیب شبکه عصبی و الگوریتم ملخ

سمیه شعبانی زاده رابری[۱]، وحید خطیبی بردسیری[۲*] و عمید خطیبی بردسیری[۳]

اطلاعات مقاله

دریافت مقاله: ۹۷/۰۵/۱۲

پذیرش مقاله: ۹۷/۱۱/۲۴

واژگان کلیدی:

قابلیت اطمینان،

پیش‌بینی نقص نرم‌افزار،

شبکه‌های عصبی پرسپترون،

الگوریتم ملخ.

چکیده

سیکل توسعه نرم‌افزار شامل آنالیز، طراحی، پیاده‌سازی و تست و یکسری فازهای دیگر است. مرحله تست نرم‌افزار یکی از مراحل هزینه‌بر توسعه نرم‌افزار است، باید به‌طور مؤثری انجام شود تا نرم‌افزار بدون خطا دست کاربران برسد. یکی از فعالیت‌های مؤثر برای توسعه نرم‌افزار و افزایش قابلیت اطمینان آن، پیش‌بینی نقص نرم‌افزار قبل از رسیدن به مرحله تست است که کمک حائز اهمیتی برای صرفه‌جویی زمانی در فرآیند تولید، نگهداری و هزینه آن می‌کند. یکی از مدل‌های کارا برای پیش‌بینی نقص نرم‌افزار، استفاده از شبکه‌های عصبی پرسپترون چندلایه با الگوریتم آموزشی پس‌انتشار خطا است. یکی از نقاط ضعف الگوریتم آموزشی پس‌انتشار خطا احتمال به دام افتادن شبکه عصبی در نقاط مینیمم محلی است. با توجه به قابلیت الگوریتم‌های فراابتکاری در خروج از دام مینیمم‌های محلی و یافتن مینیمم سراسری، در این مقاله جهت برطرف کردن ضعف الگوریتم آموزشی شبکه عصبی و بهبود دقت آن در زمینه پیش‌بینی نقص نرم‌افزار، از ترکیب الگوریتم فراابتکاری ملخ با الگوریتم آموزشی پس‌انتشار خطا استفاده شده است. جهت ارزیابی نتایج حاصل از مدل پیشنهادی، نه پایگاه داده واقعی بکار گرفته‌شده و روش ارزیابی متقاطع مبنای ارائه نتایج بوده است. عملکرد مدل پیشنهادی با شش مدل پیش‌بینی نقص نرم‌افزار مقایسه شده است. نتایج این مقایسه نشان می‌دهد که مدل پیشنهادی قادر است در تعداد زیادی از مجموعه داده، صحت و دقت بالاتری نسبت به سایر مدل‌ها ارائه دهد.

۱- مقدمه

آزمون نرم‌افزار یکی از اساسی‌ترین فازهای توسعه آن به شمار می‌رود. پروژه NOTO-Rious مثالی از اهمیت آزمایش و پیش‌بینی نقص نرم‌افزار است. NOTO-Rious نام یکی از فضاپیماهای ناسا است که در آن به دلیل یک اشکال کوچک تبدیل داده؛ ۱۲۵ میلیون دلار از دست رفت. این مثال نشان می‌دهد که رفع اشکال نرم‌افزار در حین توسعه آن، خیلی مقرون به‌صرفه‌تر است تا بعد از استقرار نرم‌افزار [۱]. در پروژه‌های نرم‌افزاری کشف و اصلاح نقص در بازه‌های زمانی موجود بسیار وقت‌گیر و در توسعه نرم‌افزار بسیار هزینه‌بر است، به همین علت تأثیر تست و بازیابی کدها کاهش می‌یابد. ازاین‌رو شناسایی ماژول‌های مستعد خطا به‌صورت خودکار، به تمرکز روی تست و بازیابی کدها، کمک می‌کند. بنابراین جمع‌آوری دقیق داده‌های مستعد خطا، نیاز به ابزاری جهت پیش‌بینی ماژول‌های مستعد خطا دارد[۲].

تشخیص مؤثر نقص‌های نرم‌افزار در واقع یک فعالیت مهم از فرآیند توسعه نرم‌افزار می‌باشد، که به بهبود و دقت

* پست الکترونیک نویسنده مسئول: khatibi78@yahoo.com

۱.گروه علمی مهندسی کامپیوتر، موسسه آموزش عالی غیرانتفاعی غیردولتی جاوید، جیرفت

۲. استادیار گروه مهندسی کامپیوتر، واحد بردسیر، دانشگاه آزاد اسلامی، بردسیر، ایران

۳. استادیار گروه مهندسی کامپیوتر، واحد بردسیر، دانشگاه آزاد اسلامی، بردسیر، ایران

پیش‌بینی نقص می‌تواند کمک بسزایی کند. به همین دلیل پیش‌بینی نقص نرم‌افزار یک موضوع تحقیقاتی مهم در مهندسی نرم‌افزار بیان شده است. با یافتن مدل‌های مطلوب برای پیش‌بینی نقص نرم‌افزار اغلب تعدادی از نقص‌های توزیع‌شده را مورد تجزیه‌وتحلیل قرار می‌دهند [۳]. بنا به یک گزارش منتشرشده در سال ۲۰۱۳، ۳,۷ تریلیون دلار در سراسر جهان صرف هزینه‌های نرم‌افزار می‌شود. بررسی نشان داد که ۲۳ درصد از این هزینه در تضمین کیفیت و آزمودن صرف شده است [۱]. گاهی رخ دادن خطا در نرم‌افزار می‌تواند باعث ضررهای مالی و حتی در برخی کاربردها باعث ضررهای جانی گردد. به همین دلیل تضمین قابلیت اطمینان به عنوان یک نیازمندی غیرکارکردی (کیفی) از اهمیت بسزایی برخوردار است [۴].اگر خطای موجود در فرآیند را زودهنگام بیابید، تصحیح آن، هزینه کمتری در بر خواهد داشت. پیدا کردن و رفع خطا، مستلزم هزینه بالای است. داده‌های منتشرشده از وزارت دفاع آمریکا نشان می‌دهد که در سال ۲۰۰۶ آمریکا حدود ۷۸۰ بیلیون دلار را صرف خطاهای نرم‌افزاری کرده است. پیش‌بینی خطای نرم‌افزار، مدیران نرم‌افزار را قادر می‌سازد که تلاش برای بهبود کیفیت نرم‌افزار را در قسمت‌های موردنیاز متمرکز کنند. به همین منظور روش-های مختلف مدل‌سازی پیش‌بینی خطای نرم‌افزار توسعه داده‌شده‌اند و به‌طور واقعی برای پیش‌بینی کیفیت نرم‌افزار مورداستفاده قرار می‌گیرند [۵].پیش‌بینی نقص نرم‌افزار روی روش‌های الف- تخمین تعداد نقص‌های باقیمانده در سیستم نرم‌افزاری؛ ب- کشف روابط موجود بین نقص‌ها؛ ج- طبقه‌بندی مؤلفه‌های نرم‌افزار در دو کلاس مستعد نقص و غیرمستعد نقص، تمرکز دارد [۶]. درروش اول در مراحل طراحی و نیازمندی، اسنادی توسط مهندسان نرم‌افزاری که ویژگی‌های طراحی و نیازمندی را شرح می‌دهند آماده می‌شود. این اسناد توسط چندین (۳ تا ۵) کارشناس بررسی می‌شود. هرکدام از کارشناس‌ها قبل از تائید نهایی اسناد به مسائلی که باید حل شوند (با توجه به اعتقاداتشان) توجه می‌کنند. فهرستی از تمام بررسی‌های انجام‌شده تهیه می‌شود. اگر میزان همپوشانی مسائلی که در بررسی‌های انجام‌شده کشف نشده‌اند، کوچک باشد اجازه رفتن به مرحله بعدی داده می‌شود. درروش دوم ناقص یا غیرناقص بودن ماژول نرم‌افزاری از طریق روش‌های مبتنی بر استخراج قوانین انجمنی تشخیص داده می‌شود[۷]. اصلی-ترین روش پیش‌بینی نقص نرم‌افزار، روش سوم است.درروش طبقه‌بندی (روش سوم) از روش‌های یادگیری ماشین استفاده می‌شود. درروش طبقه‌بندی با توجه به سابقه ماژول ناقص، مدلی استخراج می‌شود که بر اساس آن بتوان با دقتی مناسب پیش‌بینی نقص در ماژول جدید را انجام داد. پژوهش‌های قبلی بر اساس یادگیری از متریک‌های به‌دست‌آمده از ماژول‌های نرم‌افزاری نشان می‌دهد که ارتباطی قوی بین این متریک‌ها و پیش‌بینی نقص وجود دارد [۸].ادامهٔ این مقاله در هشت قسمت سازمان‌دهی شده است: بخش دوم به مرور کارهای مرتبط می‌پردازد. بخش سه و چهار و پنج به ترتیب الگوریتم ملخ و دیتاست، شبکه عصبی را توضیح می‌دهند. مدل پیشنهادی در بخش ششم آورده شده و بخش هفت و هشت نیز به ترتیب نحوهٔ ارزیابی و نتایج به دست آمده را نشان می‌دهند. در نهایت بخش نهم به نتیجه‌گیری و پیشنهاد کارهای آینده اختصاص دارد.

۲- کارهای مرتبط

روش‌های مختلفِ مدل‌سازی پیش‌بینی خطا در نرم‌افزار به دودسته تقسیم‌شده‌اند:

- روش‌های آماری[1] (الگوریتمی)
- روش‌های یادگیری ماشین[2] (غیر الگوریتمی)

روش‌های آماری، از توزیع‌های آماری، برای پیش‌بینی خطای نرم‌افزار استفاده می‌کنند . احتمال بروز خطا در یک ماژول نرم‌افزاری را محاسبه می‌نمایند [۹]. در روش‌های یادگیری ماشین، از الگوریتم‌های یادگیری ماشین، استفاده می‌شود. برای پیش‌بینی خطای نرم‌افزار، الگوریتم یادگیری ماشین را روی دادگان ارزیابی[3] مخصوصِ خطا در نرم‌افزار، پیاده‌سازی و اجرا کرده و با توجه به معیارهای ارزیابیِ[4] دقت، نتایج را می‌سنجند. آزمون نرم‌افزار، یک فعالیت بسیار پیچیده در طول تولید نرم‌افزار است. مدل‌های پیش‌بینی به متخصصان در این مورد با استفاده از روش‌های یادگیری ماشین، کمک کرده‌اند[۱۰]. طبقه‌بندی شکلی از تحلیل داده‌ها محسوب می‌شود که می‌توان به کمک آن مدلی

[1] Statistical Method
[2].Machine Learning Method
[3] Datasets
[4] Evaluation Measures

جهت توصیف داده‌ها استخراج کرد. با کمک این مدل می‌توان نمونه‌ها را به یکی از چندین طبقه تعریف‌شده انتساب داد. فرآیند ساخت مدل فرایندی دومرحله‌ای است. در مرحله اول با کمک دادگان آموزش که برچسب تمام نمونه‌های آن مشخص است مدل ساخته می‌شود (مرحله یادگیری). در مرحله دوم با کمک دادگان آزمون مدل به‌دست‌آمده اعتبار سنجی می‌شود. ارزشیابی مدل با توجه به اینکه کلاس چه تعداد از نمونه‌های آزمون را درست تخمین زد است، محاسبه می‌شود. در حوزه پیش‌بینی نقص نرم‌افزار طبقه‌بندهای مختلفی ازجمله رگرسیون منطقی [۱۱-۱۳] ، جنگل تصادفی[۱۴, ۱۵] ، نایوبیز [۱۴, ۱۶-۱۸] ، شبکه عصبی MLP[1] [۱۸, ۱۹] ،SVM[2] و توسعه‌های آن[۲۰]وKNN[3] [۱۲, ۲۰] بکار گرفته می‌شود.شبکه عصبی یکی از پرکاربردترین روش‌ها جهت پیش‌بینی خطا در نرم‌افزار است. زانگ[4] و همکاران ، روش پیش‌بینی خطای نرم‌افزاری جدید بر اساس شبکه عصبی خاکستری معرفی کردند ،در این مطالعه بیشتر تمرکز روی مسئله کاهش خطا و تکنیک جبران خطا بود [۲۱] .آرار[5] و همکاران در استراتژی خود ترکیبی از شبکه عصبی مصنوعی و الگوریتم کلونی زنبورعسل استفاده کردند. پیاده‌سازی الگوریتم پیشنهادی در محیط متلب و بر روی پروژه های cm1,kc1,kc2,pc1,jm1 از مخزن ناسا انجام شده است و نتایج پیاده‌سازی نشان‌دهنده برتری الگوریتم پیشنهادی از لحاظ هزینه و دقت و صحت نسبت به الگوریتم پس‌انتشار خطا است [۱]. الگوریتم‌های هوشمند مانند الگوریتم ژنتیک توانایی بالایی در پیش‌بینی دارد، می‌توان از آن‌ها در پیش‌بینی وضعیت آتی نرم‌افزار یا پیش‌بینی خطای نرم‌افزاری استفاده نمود.فاضل روشی برای پیش‌بینی خطای نرم‌افزار با استفاده از الگوریتم ژنتیک ارائه داده است. هدف از ارائه این روش پیش‌بینی خطای نرم‌افزار با سرعت و دقت بالاتر است و همچنین ارائه ساختاری که به‌سادگی قابل پیاده‌سازی و تعمیم باشد. [۲۲].شران[6] و همکاران، یک مدل برای پیش‌بینی بهتر کیفیت نرم‌افزار با استفاده از طبقه‌بند شبکه عصبی ارائه داده‌اند. موارد آزمون به طبقه‌بندی که با الگوریتم بهینه‌ساز فاخته ترکیب شده است تا فرآیند کلاس‌بندی دقیق‌تر انجام شود، داده می‌شود. سپس کیفیت نرم‌افزار به کمک قابلیت نگهداری و قابلیت اطمینان اندازه‌گیری می‌شود. از تجزیه و تحلیل مقایسه روشن است که روش پیشنهادی کیفیت بهتری در مقایسه با سایر روش‌های موجود به دست آورده است [۲۳]. پال[7] و همکاران، دو مدل پیشنهادی، پیش‌بینی خطای نرم‌افزار به کمک شبکه عصبی مصنوعی ارائه کردند. شبکه عصبی با دو روش ترکیبی پیاده‌سازی شده است: الف-شبکه عصبی با استفاده از الگوریتم ژنتیک ب- شبکه عصبی با استفاده از الگوریتم جفت‌گیری پرندگان. مقایسه‌ها به‌طور واضح نشان می‌دهند که صحت و دقت مدل پیشنهادی، ترکیب شبکه عصبی با الگوریتم جفت‌گیری پرندگان بهتر از مدل پیشنهادی، ترکیب شبکه عصبی با الگوریتم ژنتیک است [۲۴]. ماشین بردار پشتیبان یک روش طبقه‌بندی پیشرفته‌ای هست که برای طبقه‌بندی خطا مناسب است.رانگ[8] و همکاران، مدل پیش‌بینی خطای نرم‌افزار با ترکیب ماشین بردار پشتیبان و الگوریتم خفاش ارائه کردند. این مدل پیشنهادی باعث بهبود توانایی محاسبات غیرخطی svm و قابلیت بهینه‌سازی پارامترهای الگوریتم خفاش می‌شود. نتایج نشان می‌دهد، مدل ترکیبی SVM با تغییر رنج الگوریتم خفاش برای پیش‌بینی خطای نرم‌افزار، میزان صحت بیشتری در مقایسه با مدل ماشین بردار پشتیبان و دیگر مدل‌های سنتی دارد [۲۵]. هدف اصلی مقاله راچیکا[9] و همکار، عبارت است از: الف) انتخاب ویژگی برای پیش بینی نقص با استفاده از الگوریتم تکاملی پیشنهادی جهت کاهش ویژگی ب) مقایسه تکنیک های یادگیری ماشین ج) استفاده از دقت و فراخوانی به عنوان معیار کارایی برای پیش بینی نقص د) اعتبار دهی ۱۰ بار بر روی هر مدل انجام شده است. در این استراتژی، کلاس خطادار را با استفاده از ۵ تکنیک یادگیری ماشین و ۲ تکنیک الگوریتم تکاملی برای انتخاب ویژگی پیش بینی شده است. الگوریتم های تکاملی را برای انتخاب ویژگی مناسب برای هر یک از تکنیک های طبقه بندی اعمال شده در پنج بسته آندروید منبع باز استفاده شده است . نتایج نشان می دهد مدل های پیش بینی که از الگوریتم های تکاملی برای انتخاب ویژگی

[1] Multi-layer Perceptron
[2] Support Vector Machine
[3] Nearest Neighbor
[4] Zhang
[5] Arar
[6] Sheoran
[7] Pal
[8] Rong
[9] Ruchika

استفاده شده است، قدرت پیش بینی کننده بهتری نسبت به مدلهایی که از تکنیک انتخاب ویژگی استفاده نکرده دارد [۲۶].

در مطالعات انجام‌شده، کاربردی از الگوریتم ملخ دیده نمی‌شود .با توجه به اینکه الگوریتم ملخ یکی از محبوب‌ترین الگوریتم‌های بهینه‌سازی مبتنی بر چند راه‌حل است که در سال ۲۰۱۷ معرفی شده است. دارای فرآیند اکتشاف قوی‌تر، مکانیسم جستجوی قوی در فضای مسئله، بهینه‌سازی با سرعت بیشتر انجام می دهد. در ترکیب با شبکه عصبی کارایی بهینه‌تری دارد [۲۷]. در مدل پیشنهادی ترکیبی از شبکه عصبی و الگوریتم ملخ استفاده شده است.

۳-الگوریتم ملخ

الگوریتم ملخ نیز مانند سایر الگوریتم‌های الهام گرفته‌شده از طبیعت، به‌صورت منطقی فرآیند جستجو را به دو بخش تقسیم می‌کند: اکتشاف و بهره‌برداری. در اکتشاف، عامل‌های جستجو تشویق به حرکت‌های تصادفی می‌شوند. در مرحله بهره‌برداری آن‌ها تمایل به حرکت‌های محلی و اطراف مکان خود دارند. این دو عمل و همچنین جستجوی هدف، به‌طور طبیعی توسط ملخ انجام می‌گیرد. مدل ریاضی که برای شبیه‌سازی رفتار ملخ‌ها استفاده می‌شود، فرمول(۱) می‌باشد [۲۷]

$$\mathbf{X_i = S_i + G_i + A_i} \qquad (۱)$$

در فرمول X_i، موقعیت i امین ملخ را مشخص می‌کند، S_i تعامل اجتماعی و G_i نیروی گرانش اعمال‌شده به ملخ i ام می‌باشد، A_i جهت باد را نمایش می‌دهد. برای ایجاد رفتار تصادفی می‌توان رابطه (۱) را به‌صورت زیر بازنویسی کرد؛ که در فرمول (۲) r_1,r_2,r_3 اعداد تصادفی در بازه $[۰،۱]$ می‌باشند.

$$\mathbf{X_i = r_1 S_i + r_2 G_i + r_3 A_i} \qquad (۲)$$

مقدار S_i یعنی تعامل اجتماعی برای ملخ i ام با توجه به فرمول (۳) محاسبه می‌شود.

$$\mathbf{Si}=\sum_{\substack{j=1\\ j\neq i}}^{N} s\left(d_{ij}\right)\widehat{d_{ij}} \qquad (۳)$$

که در آن d_{ij}، فاصله بین ملخ i ام تا ملخ j ام را نشان می‌دهد به‌صورت $d_{ij=}|x_j-x_i|$ محاسبه می‌شود. s یک تابع برای تعریف فشار نیروی اجتماعی می‌باشد همان‌طور که در رابطه (۳) نشان داده شده است. $\widehat{d_{ij}} = \frac{x_j-x_i}{d_{ij}}$ یک بردار واحد از i امین ملخ به j امین ملخ میباشد.

تابع S که نیروی اجتماعی را تعریف می‌کند طبق رابطه (۴) محاسبه می‌شود: که در آن f نشان‌دهنده شدت جاذبه و l نشان‌دهنده طول مقیاس جاذبه است.

$$\boldsymbol{s(r) = fe^{\frac{-r}{l}} - e^{-r}} \qquad (۴)$$

که در آن f نشان‌دهنده شدت جاذبه و l نشان‌دهنده طول مقیاس جاذبه می‌باشد. اگرچه تابع s قادراست تا فضای بین دو ملخ را به نواحی دافعه و جاذبه و آسایش تقسیم کند، این تابع مقادیر نزدیک به صفر بافاصله بیشتر از ۱۰ همانند آنچه در شکل (۱) نشان داده شده است را برمی‌گرداند. بنابراین، این تابع قادر نیست تا نیروی شدیدی رابین دو ملخ که فاصله بین آن‌ها زیاد است را اعمال کند. برای حل این مشکل، ما فاصله بین دو ملخ را به بازه [۱،۴] نگاشت می‌کنیم.

مؤلفه G در رابطه (۵) به‌صورت زیر محاسبه می‌شود:

$$\boldsymbol{G_{i=-g\widehat{e_g}}} \qquad (۵)$$

که g ثابت گرانشی زمین و$\widehat{e_g}$ بردار واحد به سمت مرکز زمین می‌باشد.

مؤلفه A در رابطه (۶) به‌صورت زیر محاسبه می‌شود:

$$\boldsymbol{A_i = u\widehat{e_w}} \qquad (۶)$$

U ثابت رانش و$\widehat{e_w}$ بردار واحد در جهت باد می‌باشد.

ملخ‌های پوره بال ندارند، بنابراین حرکت آن‌ها به‌شـدت به جهت وزش باد بستگی دارد.

جایگزینی S و G و A در رابطه (۷) به‌صورت زیر می‌باشد:

$$\boldsymbol{X_i = \sum_{\substack{j=1\\ j\neq i}}^{N} s\left(|x_j - x_i|\right)\frac{X_J - X_i}{d_{ij}} - g\hat{e}_g + u\hat{e}_w} \quad (۷)$$

در رابطه بالا $s(r) = fe^{\frac{-r}{l}} - e^{-r}$ و N تعداد ملخ‌هاست.رابطه (۷) مانع کاوش و بهره‌برداری در فضای جستجوی اطراف یک راه‌حل می‌شود. نمی‌توان به‌طور مستقیم از این رابطه برای حل مسائل بهینه‌سازی مورد استفاده قرار داد. به همین دلیل یک نسخه اصلاح‌شده از این رابطه برای حل مسائل بهینه‌سازی به‌صورت رابطه (۸) ارائه شده است:

$$\boldsymbol{X_i^d = c\left(\sum_{\substack{j=1\\ j\neq i}}^{N} c\,\frac{ub_d - lb_d}{2}\, s\left(|x_j^d - x_i^d|\right)\frac{x_j - x_i}{d_{ij}}\right) + \widehat{T_d}} \qquad (۸)$$

در معادله بالا ub_d حد بالا و lb_d حد پایین در بعد d ام می‌باشد $s(r) = fe^{\frac{-r}{l}} - e^{-r}$ و $\widehat{T_d}$ مقدار بعد d ام در هدف (بهترین جوابی که تاکنون دیده‌شده است)

می‌باشد. c ثابت کاهش برای کم کردن منطقه آسایش، دافعه و جاذبه می‌باشد . S تقریباً مشبه مؤلفه S در رابطه (۱) می‌باشد. بااین‌حال ما گرانش را در نظر نمی‌گیریم (مؤلفه G) و فرض می‌کنیم که جهت باد (مؤلفه A) همیشه به سمت هدف می‌باشد.

در رابطه (۸) اولین c از سمت چپ، این جابجایی‌های ملخ‌ها در اطراف هدف را کاهش می‌دهد. به‌عبارت‌دیگر، این پارامتر تعادل بین اکتشاف و بهره‌برداری در اطراف هدف را ایجاد می‌کند. متغیر c دوم ناحیه جاذبه، دافعه و آسایش بین ملخ‌ها را کاهش می‌دهد. مؤلفه $c\frac{ub_d-lb_d}{2}\, s\left(\left|x_j^d - x_i^d\right|\right)$ در رابطه (۸) در نظر گیرید که در آن $c\frac{ub_d-lb_d}{2}$ به‌صورت خطی فضای بین ملخ‌هایی که باید اکتشاف و بهره‌برداری انجام دهند را کاهش می‌دهد. مؤلفه $s\left(\left|x_j^d - x_i^d\right|\right)$ نشان می‌دهد اگر یک ملخ باید از هدف دفع (اکتشاف) شود یا به هدف (بهره‌برداری) جذب شود.

ضریب c منطقه آسایش متناسب با تعداد تکرارها را کاهش می‌دهد. به‌صورت فرمول (۹) محاسبه می‌شود:

$$c = c_{max} - l\frac{c_{max}-c_{min}}{L} \qquad (۹)$$

در رابطه (۹) c_{max} بیشترین مقدار و c_{min} کمترین مقدار را دارد. l شماره تکرار فعلی را نشان می‌دهد. L حداکثر تعداد تکرار الگوریتم است. پارامتر c تأثیر زیادی بر روی حرکت ملخ‌ها و همگرایی آن‌ها دارد. الگوریتم GOA[1] بهینه‌سازی را با ایجاد یک مجموعه تصادفی از راه‌حل‌ها شروع می‌کند. عامل‌های جستجو موقعیت خود را بر اساس رابطه (۸) به‌روزرسانی می‌کنند. موقعیت بهترین هدف به‌دست‌آمده تاکنون در هر تکرار به‌روزرسانی می‌شود. علاوه بر این، فاکتورc با رابطه (۹) محاسبه می‌شود و فاصله بین ملخ‌ها به بازه [۱،۴] در هر تکرار نرمال می‌شود. به‌روزرسانی موقعیت تا زمانی که شرایط خاتمه برقرار نشود تکرار می‌شود. موقعیت و شایستگی بهترین هدف درنهایت به‌عنوان بهترین تقریب از بهینه سراسری به خروجی داده می‌شود.

۴-توصیف مخزن داده

دیتاست ناسا معمولاً به‌عنوان دیتاست معیار سنجش برای مسائل پیش‌بینی خطا به کار می‌رود. پروژه‌های نرم‌افزاری هر دیتاست شامل چندین ماژول نرم‌افزاری است که متریک‌های کیفیت به‌عنوان ورودی ماژول‌ها می‌باشد. هر ماژول شامل یک برچسب خروجی، از خطادار بودن یا بدون خطاست که نشان می‌دهد. خطایی در ماژول مربوطه دیده شده است. برچسب‌گذاری ماژول‌ها به‌صورت دستی بعد از مرحله آزمون انجام می‌شود[۱]. شرح مختصری از ویژگی‌های مجموعه داده‌هایی که در این تحقیق مورد استفاده قرارگرفته‌اند در جدول ۱ ذکرشده است.

در ستون اول این جدول نام مجموعه داده‌ها آورده شده و در ستون‌های بعدی به ترتیب زبان برنامه‌نویسی، تعداد ویژگی‌ها، تعداد ماژول‌ها و درصد خطای موجود در هر مجموعه داده که نمایانگر درصد ماژول‌های خطادار است نشان داده شده است.

جدول ۱: ویژگی‌های مجموعه داده استفاده شده

مجموعه داده	زبان برنامه‌نویسی	تعداد ویژگی	تعداد ماژول	درصد خطا
Cm1	C	۲۱	۴۹۸	٪۱۰
Jm1	C	۲۱	۱۰۸۸۵	٪۱۹
Kc1	C++	۲۱	۲۱۰۹	٪۱۵
Kc2	C++	۲۱	۵۲۲	٪۲۱
Kc3	Java	۳۹	۴۲۹	٪۹
Pc1	C	۲۱	۱۱۰۹	٪۷
Pc2	C	۳۷	۴۵۰۵	٪۰,۵
Pc3	C	۳۷	۱۵۶۳	٪۱۰
Pc4	C	۳۷	۱۴۵۸	٪۱۲

دیتاست ناسا شامل ۲۱ متریک از نوع مکایب و هالستد، مشتق شده هالستد است. تعدادی از محققین بر این نظرند که متریک‌های مشتق شده هالستد برای پیش‌بینی نقص نرم‌افزار زیاد کاربردی ندارند.به همین دلیل کمتر استفاده می‌شوند. متریک‌های مکایب و هالستد به‌طور فراوان برای اندازه‌گیری کیفیت ماژول‌های نرم‌افزار به کار می‌روند. هر ماژول به‌واسطه زیر برنامه یا متد یا تابع در زبان‌های برنامه‌نویسی روالی مانند c و به‌وسیله کلاس در زبان‌های شی گرا مانند (c++,java) نمایش داده می‌شود [۱]. جدول ۲ خلاصه‌ای از ۲۱ متریک که برای هر ماژول

[1] Grasshopper Optimization Algorithm

جمع‌آوری شده است را نشان می‌دهد.

جدول ۲: خلاصه‌ای از متریک‌ها(متد-سطح) [۱]

شرح	متریک	نوع
تعداد خطوط کد	loc	مکایب
تعداد مسیرهای مستقل -e n+2	V(g)	
پیچیدگی EV(G)=V(G)-m	Ev(g)	
میزان پیچیدگی	Iv(g)	
تعداد کل عملگرها و عملوندها	n	هالستد
تعداد مقایسه‌های N*log2(mu)	v	
میزان هوشمندی L'*V'	l	
میزان سختی	d	
میزان هوشمندی	i	
میزان تلاش V/L	e	
میزان تخمین خطا	b	
زمان مصرفی E/18 و برحسب ثانیه)	Locoed	
تعداد خطوط کد	lOComment	
تعداد خطوط توضیحات	lOBlank	
تعداد خطوط خالی.	lOCodeAndComment	
تعداد خطوط شامل کد و توضیحات.		
تعداد عملگرهای یکتا	uniqOp	مشتق شده هالستد
تعداد عملوندهای یکتا	uniqOpnd	
تعداد کل عملگرها	totalOp	
تعداد کل عملوندها	totalOpnd	
تعداد کل	branchCount	

۵-شبکه عصبی

امروزه شبکه‌های عصبی کاربرد فراوانی در پیش‌بینی خطا دارند [۲۸-۳۰]. شبکه عصبی مدلی بر اساس مغز انسان است. به دو نوع شبکه‌های پیش‌خور (FFN[1]) و پس‌خور (RNN[2]) تقسیم می‌شوند. تفاوت آن‌ها در این است که در شبکه‌های پس‌خور، حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون های همان لایه و یا لایه قبل وجود دارد. اغلب ۸۰ درصد از کاربردها از شبکه‌های عصبی پیش‌خور استفاده می‌شود.

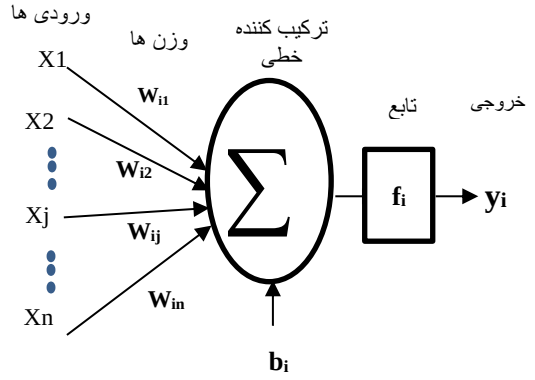

شکل ۱: شکل کلی یک پرسپترون[۱]

شکل (۱) یک پرسپترون با اجزای نشان داده شده است.شبکه عصبی پرسپترون از چند پرسپترون و چندلایه ایجاد می‌شود. در شبکه‌های پرسپترون چندلایه هر نرون در هر لایه به تمام نرون های لایه قبل متصل می‌باشد. به چنین شبکه‌هایی، شبکه‌های کاملاً مرتبط می‌گویند. جهت آموزش شبکه‌های پرسپترون، الگوریتم‌های آموزشی مختلفی وجود دارد. شکل (۲) ساختار یک MLP را با دولایه مخفی و یک‌لایه ورودی و یک‌لایه خروجی نشان می‌دهد.

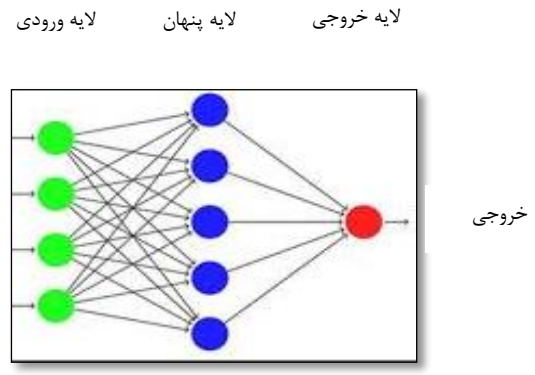

شکل ۲: ساختار شبکه عصبی mlp

خروجی شبکه عصبی طبق فرمول (۱۰) به دست می‌آید:

$$Y_i = f_i(\sum_{j=1}^{n} x_i w_{ij} + b_i) \qquad (۱۰)$$

که Y_iخروجی شبکه و x_i ورودی شبکه می‌باشند.w_{ij}

[1] Feed Forward Network

[2] Recurrent Neural Network

وزن‌های اتصالی بین گره‌های ورودی و خروجی است. b_i بایاس می‌باشد. f_i تابع انتقال است. الگوریتم یادگیری پس‌انتشار خطا، یکی از رایج‌ترین الگوریتم‌ها جهت آموزش شبکه‌های عصبی MLP می‌باشد. به عبارتی توپولوژی شبکه‌های MLP، با قانون یادگیری پس‌انتشار خطا تکمیل می‌شود. این قانون تقریبی از الگوریتم بیشترین نزول [۳۱] است. به‌طور خلاصه، فرآیند پس‌انتشار خطا از دو مسیر اصلی تشکیل می‌شود. مسیر رفت و مسیر برگشت. در مسیر رفت، یک الگوی آموزشی به شبکه اعمال می‌شود و تأثیرات آن از طریق لایه‌های میانی به لایه خروجی انتشار می‌یابد. تا اینکه نهایتاً خروجی واقعی شبکه MLP، به دست می‌آید. در این مسیر، پارامترهای شبکه (ماتریس‌های وزن و بردارهای بایاس)، ثابت و بدون تغییر در نظر گرفته می‌شوند. در مسیر برگشت، برعکس مسیر رفت، پارامترهای شبکه MLP تغییر و تنظیم می‌گردند. این تنظیمات بر اساس قانون یادگیری اصلاح خطا انجام می‌گیرد. سیگنال خطا، در لایه خروجی شبکه تشکیل می‌گردد. [۳۲]

تابع خطای E به‌صورت (۱۱) می‌باشد:

$$E(W(t))=\frac{1}{n}\sum_{j=1}^{n}\sum_{k=1}^{n}(dk-ok) \qquad (۱۱)$$

برای درک بهتر نقش شبکه عصبی در مدل پیشنهادی، ساختار شبکه عصبی برای مجموعه داده pc1 در شکل (۳) نشان داده شده است.

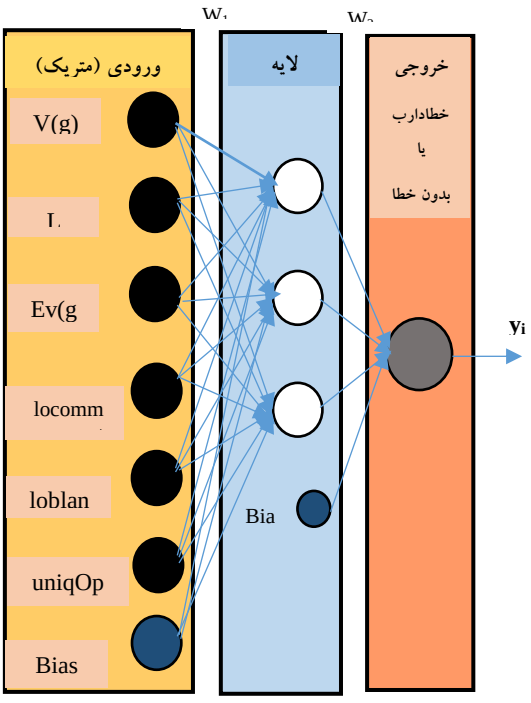

شکل ۳: ساختار شبکه عصبی برای دیتاست pc1 [۱]

۶-مدل پیشنهادی

شبکه عصبی یکی از روش‌های طبقه‌بندی دقیق و تقریب زننده‌های جهانی برای پیش‌بینی نقص نرم‌افزار است. برای آموزش وزن‌های شبکه عصبی، از یک شبکه عصبی با ساختار مشخص و معینی، یعنی تعداد ثابتی لایه پنهانی و نرون در هر لایه برای شبکه موردنظر استفاده می‌کنیم. فرآیند آموزش وزن‌های شبکه با همان معماری مشخص آغازشده و تا انتهای آموزش همان ساختار را برای شبکه داشتیم. مشخص نیست که آن ساختار بهترین ساختار موجود برای شبکه عصبی است. به‌روزرسانی ساختار شبکه عصبی تبدیل به یک مسئله بهینه می‌شود. از جهتی الگوریتم ملخ، یک روش هوش جمعی و قوی و جدید برای یافتن نقاط بهینه سراسری در فضای جستجو است. بنابراین می‌توان از الگوریتم ملخ، برای پیدا کردن ساختار بهینه در شبکه عصبی استفاده کرد. در روش پیشنهادی برای پیش‌بینی نقص‌های موجود در نرم‌افزار، یک سیستم ترکیبی از شبکه‌های عصبی و الگوریتم ملخ استفاده شده است . در آن برای بالا بردن دقت و صحت سیستم و فرار از به دام افتادن الگوریتم آموزشی شبکه عصبی در مینیمم محلی، ابتدا الگوریتم ملخ وزن‌های بهینه‌شده را که به دقت قابل قبولی رسیده است، را به الگوریتم آموزشی پس‌انتشار خطا منتقل می‌کند.

به‌عبارت‌دیگر، در روش پیشنهادی تمرکز بر این است که نقطه شروع الگوریتم آموزشی شبکه عصبی که الگوریتم پس‌انتشار خطا می‌باشد، به‌گونه‌ای انتخاب کنیم که در مینیمم‌های محلی گیر نکند. اگر الگوریتم پس‌انتشار با یک شرایط اولیه خوب و نزدیک وزن بهینه عمل جستجو را شروع کند، با سرعت بالایی به نقطه بهینه نزدیک می‌شود. در الگوریتم ترکیبی ملخ و پس‌انتشار خطا، در مراحل اولیه، پس از به دست آوردن بهترین ساختار شبکه عصبی توسط الگوریتم ملخ، وزن‌های شبکه عصبی نیز توسط این الگوریتم پیدا می‌شوند. پس از یک تعداد تکرار معین یا پس از رسیدن به یک دقت از پیش تعیین‌شده، الگوریتم یادگیری از الگوریتم ملخ به الگوریتم پس‌انتشار خطا سوییچ می‌شود. به‌این‌ترتیب الگوریتم پس‌انتشار خطا با یک شرایط اولیه خوب و در نزدیکی نقطه بهینه سراسری شروع می‌شود. و طی تکرارهای کم به‌دقت بالایی می‌رسد..بنابراین در مدل پیشنهادی، علاوه بر بهینه کردن وزن‌های شبکه عصبی، ساختار آن را نیز توسط الگوریتم ملخ بهینه

می‌کنیم. در واقع یک الگوریتم ملخ در بدنه سیستم پیشنهادی داریم، که فرآیند بهینه‌سازی ساختار شبکه عصبی را انجام می‌دهد. یک جمعیت از ملخ‌ها در داخل این بدنه داریم که فرآیند بهینه‌سازی وزن‌های شبکه عصبی را انجام می‌دهد.

۶-۱- مرحله آموزش در روش پیشنهادی

با استفاده از ارزیابی متقاطع نمونه اصلی دیتاست به ده زیر نمونه تصادفی تقسیم می‌شود. از این ۱۰ تا زیر نمونه، ۹ تای آن برای داده‌های آموزشی استفاده می‌شود و ۱ زیرنمونه، برای تست مدل استفاده می‌شود.

علت تقسیم دیتاست به دو تا این است که شبکه عصبی فقط با یکسری داده‌های خاص آموزش نبیند . اگر داده‌های جدیدی به‌عنوان ورودی به آن داده شود خوب عمل کند. شبکه عصبی قابلیت تعمیم دهی داشته باشد و خطای overfitting روی ندهد. سپس الگوریتم بهینه‌ساز ملخ فراخوانی می‌شود، در هر مرحله وزن‌های شبکه عصبی را بهینه می‌کند. داده‌های آموزشی و تعداد نرون‌ها به ورودی الگوریتم ملخ داده می‌شود . توسط تابع هدف الگوریتم ملخ، وزن‌های w_{e1},w_{e2} و بایاس‌های b_{i1},b_{i2} و خطای شبکه عصبی محاسبه می‌شود و به‌عنوان خروجی الگوریتم به دست می‌آید. مراحل آموزش شبکه عصبی توسط الگوریتم ملخ در شکل (۴) نشان داده شده است. این شکل نمایانگر مراحل آموزش شبکه عصبی برای پیش‌بینی می‌باشد.

۶-۲- تابع شایستگی در روش پیشنهادی

در مدل پیشنهادی، بعد از ایجاد ساختار شبکه عصبی و مشخص کردن وزن‌ها، بایاس‌ها و الگوریتم آموزشی پس‌انتشار خطا به کمک تابع ()mse، (میانگین مربعات خطا) هزینه محاسبه می‌شود. این تابع مقدار موردنظر (triny) را از خروجی شبکه عصبی کم می‌کند و بهترین حالت این است که خروجی تابع ()mse صفر شود.

۶-۳- مرحله آزمون در روش پیشنهادی

پس از انجام مرحله آموزش شبکه عصبی در مدل پیشنهادی، وارد مرحله آزمون و تست مدل پیشنهادی جهت سنجش عملکرد شبکه عصبی در مدل پیشنهادی می‌شود. نحوه انجام مرحله آزمون شبکه عصبی در شکل (۵) نشان داده شده است.

پس از انجام آموزش مدل پیشنهادی، یکسری پارامتر از مدل آموزش به دست می‌آید .

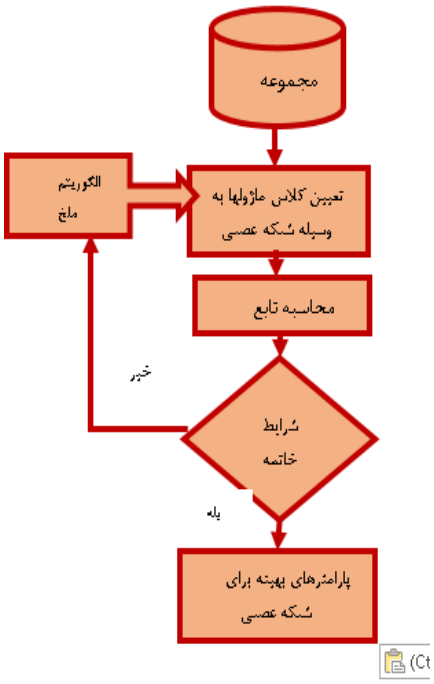

شکل ۴: آموزش شبکه عصبی در مدل پیشنهادی

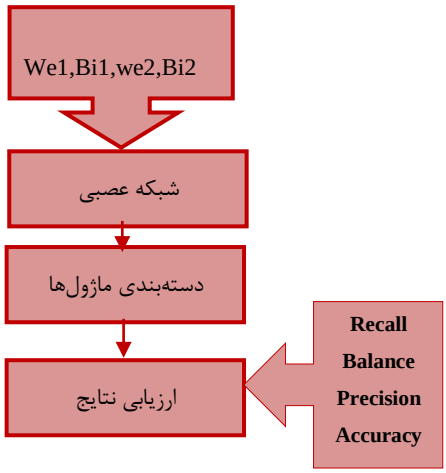

شکل ۵: آزمون شبکه عصبی در مدل پیشنهادی

به‌عنوان ورودی در مرحله آزمون از آن‌ها استفاده می‌شود. علاوه بر پارامترهای $w_{e1},w_{e2}, b_{i1},b_{i2}$ دو پارامتر X و Y نیز وجود دارد که این پارامترها مربوط به داده‌های تست می‌باشد. اکنون باید شبکه عصبی با پارامترهای بهینه‌شده ماژول‌های تست را مورد پیش‌بینی قرار دهد. در این بخش از روش ارزیابی متقاطع که در آن نمونه اصلی به‌صورت تصادفی به ۱۰ زیرنمونه تقسیم می‌شود، استفاده شده است. از ۱۰ زیرنمونه ۹ تای آن‌ها برای داده‌های آموزشی و یک زیرنمونه به‌منظور تست مدل استفاده می‌شود. همچنین فرآیند ارزیابی متقاطع، ۱۰ بار تکرار

می‌شود. میانگین نتایج حاصل از ۱۰ بار اجرا به‌عنوان نتایج نهایی مورد استفاده قرار می‌گیرد. X ماتریسی $m \times n$ و Y ماتریسی $n \times 1$ می‌باشد. m معرف تعداد ویژگی‌ها و n تعداد ماژول‌ها در هر مجموعه داده نشان می‌دهد. ارزیابی متقاطع موجب می‌شود دقت آزمون مدل بالا برود.

۶-۴-پارامترهای ارزیابی مدل پیشنهادی

کارایی مدل پیشنهادی با استفاده از معیارهای ارزیابی، به کمک ماتریس درهم‌ریختگی در جدول (۳) نشان داده شده است.این ماتریس نمونه‌هایی که برای هر کلاس به‌درستی و به اشتباه تشـخیص داده‌شده‌اند، را نمایش می‌دهد.TP و TN به ترتیب تعداد نمونه‌های کلاس مثبت و منفی که به‌درستی طبقه‌بندی شده‌اند را نشان می‌دهند. FN تعداد نمونه‌های کلاس مثبت می‌باشد که به اشتباه منفی پیش‌بینی شده‌اند.درحالی‌که FP تعداد نمونه‌های منفی می‌باشد که به اشتباه مثبت معرفی شده‌اند. مورد بررسی قرار گرفت.

جدول ۳: ماتریس درهم‌ریختگی

دسته‌بندی پیش‌بینی کننده	دسته‌بندی واقعی	
	حاوی نقص	عاری از نقص
حاوی نقص	TP	FP
عاری از نقص	FN	TN

در این مقاله کارایی مدل پیشنهادی با استفاده از مشهورترین و پرکاربردترین معیارها شامل موارد فراخوانی مجدد(۱۲) ، توازن (۱۳)، دقت (۱۴)، صحت (۱۵) می‌باشد اندازه‌گیری شده است:

$$\text{Recall} = \frac{TP}{TP + FN} \qquad (۱۲)$$

$$B = 1 - \sqrt{\frac{1}{2}\left(\left(\frac{FN}{TP + FN}\right)^2 + \left(\frac{FP}{TN + FP}\right)^2\right)} \qquad (۱۳)$$

$$\text{Precision} = \frac{TP}{TP + FP} \qquad (۱۴)$$

$$\text{Acc} = \frac{TP + TN}{TP + TN + FP + FN} \qquad (۱۵)$$

۶-۵- پارامترهای تنظیم‌شده مدل پیشنهادی

پارامترهای مؤثر در الگوریتم ملخ و شبکه عصبی در جدول ۴ و ۵ آمده است. این مقادیر با سعی و خطا به‌صورت تجربی تعیین شده است. معیار انتخاب مقادیر، رسیدن به نتایج بهینه‌تر بوده است.

جدول ۴: پارامترهای الگوریتم ملخ در مدل پیشنهادی

پارامتر	مقدار
SearchAgents_no	تعداد عامل‌های جستجو
Max_iter	تعداد تکرار
dim	تعداد پارامترهای مسئله که با توجه به تعداد نرون ها محاسبه می‌شود.
w_{e1},w_{e2}, b_{i1},b_{i2}	وزن‌ها و بایاس‌های بهینه‌شده.

جدول ۵: پارامترهای شبکه عصبی در مدل پیشنهادی

پارامتر	مقدار
neu	تعداد نرون های لایه‌های شبکه عصبی
w_{e1},w_{e2}, b_{i1},b_{i2} tsX,tsY	پارامترهای ورودی شبکه عصبی
err	محاسبه خطای شبکه عصبی

۶-۶-نتایج تجربی در مدل پیشنهادی

در این بخش نتایج حاصل از اجرای روش‌های پیشنهادی بر روی ۹ پایگاه داده مختلـف نمـایش داده‌شده است. این نتایج مربوط به داده‌های تست می‌باشد. با اعمال ارزیابی متقاطع ۱۰تـایی به‌دست‌آمده اسـت. جدول ۶ نتایج حاصل از اجرای روش پیشنهادی بر روی پایگاه داده‌های مختلفی نشان می‌دهد:

جدول ۶: نتایج مدل پیشنهادی روی ۹ دیتاست

مخزن داده	توازن	فراخوانی	دقت	صحت
Cm1	۰,۹۸۵۰	۰,۹۶۰۰	۰,۹۷۰۰	۰,۹۲۳۰
Kc1	۰,۹۸۰۰	۰,۹۸۵۰	۰,۸۷۲۰	۰,۹۴۲۰
Kc2	۰,۹۸۴۶	۰,۹۰۰۰	۰,۸۰۰۰	۰,۹۲۰۰
Kc3	۰,۹۸۴۶	۰,۹۵۰۰	۰,۸۸۲۰	۰,۹۶۰۰
Jm1	۰,۹۸۳۹	۰,۹۸۰۰	۰,۸۸۷۱	۰,۹۸۱۴
Pc1	۰,۹۸۴۳	۰,۹۸۱۲	۰,۹۰۳۰	۰,۹۸۱۸
Pc2	۰,۸۲۳۲	۰,۹۷۴۲	۰,۹۹	۰,۹۸۸۸
Pc3	۰,۹۸۳۹	۰,۹۷۱۵	۰,۸۵۷۱	۰,۹۸۱۱
Pc4	۰,۸۵۸۶	۰,۹۷۲۰	۰,۹۷۰۰	۰,۹۳۲۰

۷-ارزیابی نتایج

برای نمایش عملکرد و کارآمدی مدل پیشنهادی، نتایج به دست‌آمده را با شش روش متداول درخت تصمیمj48[1]، نایو بیز[2]،جنگل تصادفی[3] [۳۳]، الگوریتم ترکیبی شبکه عصبی حساس به هزینه و زنبورعسل [۱]، شبکه عصبی شعاعی [۳۰] و الگوریتم ترکیبی شبکه عصبی و جهش قورباغه [۳۴] مقایسه نمودیم. به منظور درک بهتر، نتایج کلی در جداول ۷ تا ۱۰، در مقابل با سایر روش‌ها نمایش داده شده و نمودار ستونی نتایج نیز رسم شده است.

با توجه به جدول (۷)، مدل پیشنهادی در همه دیتاست‌ها در رتبه اول قرار دارد. الگوریتم شبکه عصبی در دیتاست-های (kc1,cm1,kc3,pc1) در رتبه دوم قرار دارد. الگوریتمRF در دیتاست های (kc1,cm1,pc1,pc2,pc3,pc4) در رتبه سوم و الگوریتم j48 در رتبه چهارم قرار دارد. پایین‌ترین رتبه تقریباً در همه دیتاست‌ها متلق به الگوریتم نایو بیز و در دیتاست (kc1,cm1) متعلق به شبکه عصبی حساس به هزینه است. نمودار مربوطه در شکل شماره (۶) بخش پیوست درج شده است.

جدول ۷: ارزیابی مقدار صحت در مقابل با سایر روش‌ها

دیتاست / الگوریتم	pc4	pc3	pc2	pc1	kc3	cm1	kc1
j48	۸۹	۸۴	۹۸	۸۹	۷۹	۸۳	۸۱
NB1	۸۵	۸۴	۹۸	۸۹	۷۷	۸۳	۸۱
RF	۸۹	۸۵	۹۸	۸۸	۷۵	۸۲	۸۳
sfl	-	-	-	-	-	۷۹,۴۵	۷۸,۵۳
Mlp+	-	-		-	-	۳۴,۱۷	۳۳,۶۷
mlp	-	-	-	۹۴,۲	۹۴,۷۴	۹۰,۷۵	۸۶,۷۵
مدل پیشنهاد ی	۹۳,۲	۹۸,۱	۹۸,۸	۹۸,۱	۹۶	۹۲,۳	۹۴,۲

جدول شماره۸، مقدار معیار دقت در مقایسه با سایر روش‌ها را نشان می‌دهد. مدل پیشنهادی در دیتاست های (pc4,pc3,pc2,cm1,kc1)نتایج بهبودیافته‌ای به دست آورده است. در این دیتاست‌ها رتبه یک را دارد. رتبه ۲ را الگوریتم شبکه عصبی در دیتاست های(kc1,cm1,kc3,pc1) دارد. رتبه ۳ را الگوریتم جنگل تصادفی در دیتاست های (kc1,pc3) دارد. در مابقی دیتاست‌ها رتبه الگوریتم نایوی بیز و درخت جنگلی و الگوریتم جنگل تصادفی یکسان می‌باشد.پایین‌ترین رتبه را الگوریتم ترکیبی شبکه عصبی حساس به هزینه در دیتاست (cm1,kc1) دارد. نمودار مربوطه در شکل شماره (۷) بخش پیوست درج شده است.

جدول ۸: ارزیابی مقدار دقت در مقابل با سایر روش‌ها

دیتاست / الگوریتم	pc4	pc3	pc2	pc1	kc3	cm1	kc1
j48	۸۹	۸۴	۹۸	۸۹	۷۹	۸۳	۸۱
NB1	۸۵	۸۴	۹۸	۸۹	۷۷	۸۳	۸۱
RF	۸۹	۸۵	۹۸	۸۸	۷۵	۸۲	۸۳
sfl	-	-	-	-	-	۷۹,۴۵	۷۸,۵
Mlp+	-	-	-	-	-	۳۴,۱۷	۳۳,۶۷
mlp	-	-	-	۹۴,۲	۹۴,۷۴	۹۰,۷۵	۸۶,۷
مدل پیشنهادی	۹۷	۸۵,۷	۹۹	۹۰,۳	۸۸,۲	۹۷	۸۷,۲

جدول شماره ۹، ارزیابی مقدار معیار فراخوانی در مقایسه با سایر روش ها را نمایش می دهد.مدل پیشنهادی مقدار فراخوانی را بهبود داده است . در مقایسه با الگوریتم ترکیبی شبکه عصبی حساس به هزینه رتبه یک را دارد.

جدول ۹: ارزیابی مقدار فراخوانی در مقابل با سایر روش‌ها

دیتاست / الگوریتم	pc1	jm1	kc3	kc2	kc1
Mlp+	**۷۹,۹۳**	**۸۰,۲۶**	**۷۹,۹۳**	**۷۲,۲۲**	۹۱,۳۱
مدل پیشنهادی	**۹۰,۳**	**۹۳,۲**	**۹۸**	**۹۰**	۹۶

شکل شماره (۸)، نمودار مقدار فراخوانی در مقایسه با سایر روشها را نشان می دهد.

جدول شماره ۱۰، ارزیابی مقدار معیار توازن در مقایسه با سایر روش‌ها را نمایش می دهد. مدل پیشنهادی مقدار توازن را بهبود داده است و در مقایسه با الگوریتم ترکیبی شبکه عصبی حساس به هزینه رتبه یک را دارد.

شکل شماره (۹)، نمودار مقدار توازن در مقایسه با سایر روشها را نشان می دهد.

[1] Decision tree J48
[2] Naive Bayes
[3] Random Forest

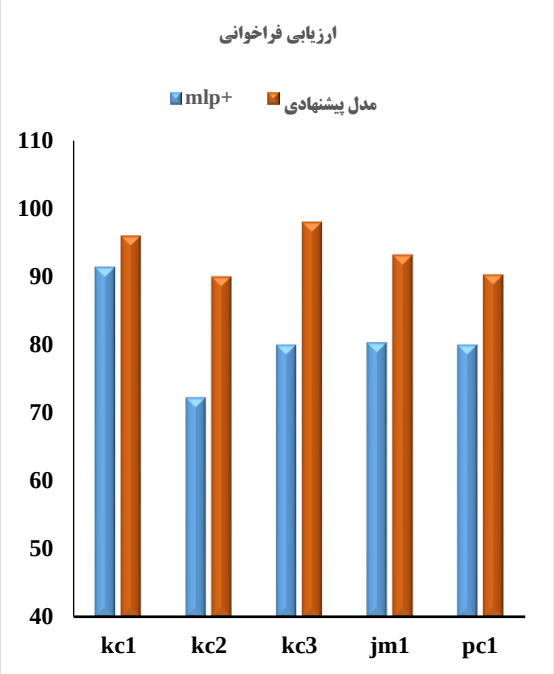

شکل ۸: ارزیابی مقدار معیار فراخوانی در مقایسه با سایر روشها

جدول ۱۰: ارزیابی مقدار توازن در مقابل با سایر روش‌ها

دیتاست / الگوریتم	Kc1	Kc2	Cm1	Jm1	Pc1
Mlp+	**۷۲،۵۶**	**۷۹،۴۶**	**۶۸،۰۹**	**۶۱،۹۷**	۶۶،۶۳
مدل پیشنهادی	**۹۵،۶**	**۹۳،۲**	**۹۷،۳**	**۹۶،۹**	۹۸،۴۳

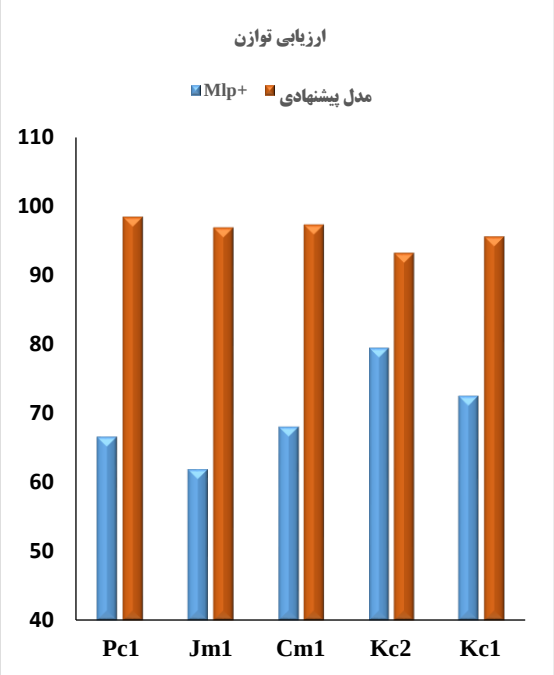

شکل ۹: ارزیابی مقدار معیار توازن در مقایسه با سایر روشها

جدول شماره ۱۱، مقایسه مقدار زمان اجرا مدل پیشنهادی را در مقایسه با سایر روش ها نمایش می دهد.

جدول ۱۱: ارزیابی زمان اجرا در مقابل با سایر روش‌ها

دیتاست / الگوریتم	pc1	jm1	kc3	kc2	kc1
j48	**۲۳**	–	**۵۸**	**۲۰**	۹۶
NB1	**۵۹**	**۶۳**	–	**۵۱**	–
RF	**۳۱**	**۲۵**	–	**۴۵**	–
sfl	**۶۸**	**۶۰**	**۸۶**	–	۸۳
Mlp+	**۸۸**	**۵۱**	**۹۳**	–	۱۰۱
mlp	**۷۰**	**۵۵**	**۸۸**	**۵۱**	۹۵
مدل پیشنهادی	**۴۹**	**۳۵**	**۶۲**	**۴۵**	۸۳

۸- نتیجه‌گیری و کار آینده

امروزه کیفیت و قابلیت اطمینان نرم‌افزار یکی از مسائل بسیار مهم درزمینه تولید نرم‌افزار می‌باشد. فناوری تشخیص خطا و نقص نرم‌افزار یکی از اهداف تحقیقاتی بسیار مهم درزمینه قابلیت اطمینان سیستم‌های نرم‌افزاری است،که مانع شکست نرم‌افزار می‌شود. ازاین‌رو عملکرد مدل پیش‌بینی نقص به‌منظور پیش‌بینی دقیق نقص در بهبود و اثربخشی مدل‌ها مهم می‌باشد. در این مقاله سعی شده است طبقه‌بندی با تکیه‌بر مدل‌های مبتنی بر یادگیری ماشین، مدلی ترکیبی و کارآمد به‌منظور پیش‌بینی نقص نرم‌افزار ارائه شود. مبنای مدل پیشنهادی شبکه عصبی پرسپترون چندلایه است. با کمک الگوریتم ملخ بهبود داده‌شده تا بتوان با قدرت بهینه‌سازی الگوریتم‌های فراابتکاری و قدرت یادگیری شبکه عصبی ضرایب مناسب و نتایج قابل قبولی تولید کرد. به‌منظور ارزیابی نتایج مدل پیشنهادی، این مدل را بر روی ۹ مجموعه داده به کار گرفته شده است و مبنای ارائه نتایج، روش ارزیابی متقاطع بوده است. عملکرد مدل پیشنهادی با ۶ مقاله معتبر که جدید منتشر شده است مورد مقایسه قرار گرفت. نتایج نشان داده‌شده در نمودارها حاکی از آن است که مدل پیشنهادی توانسته است بالاترین مقدار معیارهای ارزیابی صحت، فراخوانی، توازن را در همه مجموعه داده‌ها و معیار ارزیابی دقت در بیشتر مجموعه داده‌ها را به دست آورد. با توجه به ضرورت پیش‌بینی نقص نرم‌افزار در تولید نرم‌افزار مدل پیشنهادی قابل گسترده است برای مثال استفاده از الگوریتم‌های انتخاب ویژگی، ارزیابی مدل پیشنهادی با سایر معیارهای ارزیابی و استفاده از الگوریتم‌های فراابتکاری جدیدتر از دیگر کارهای آینده است.

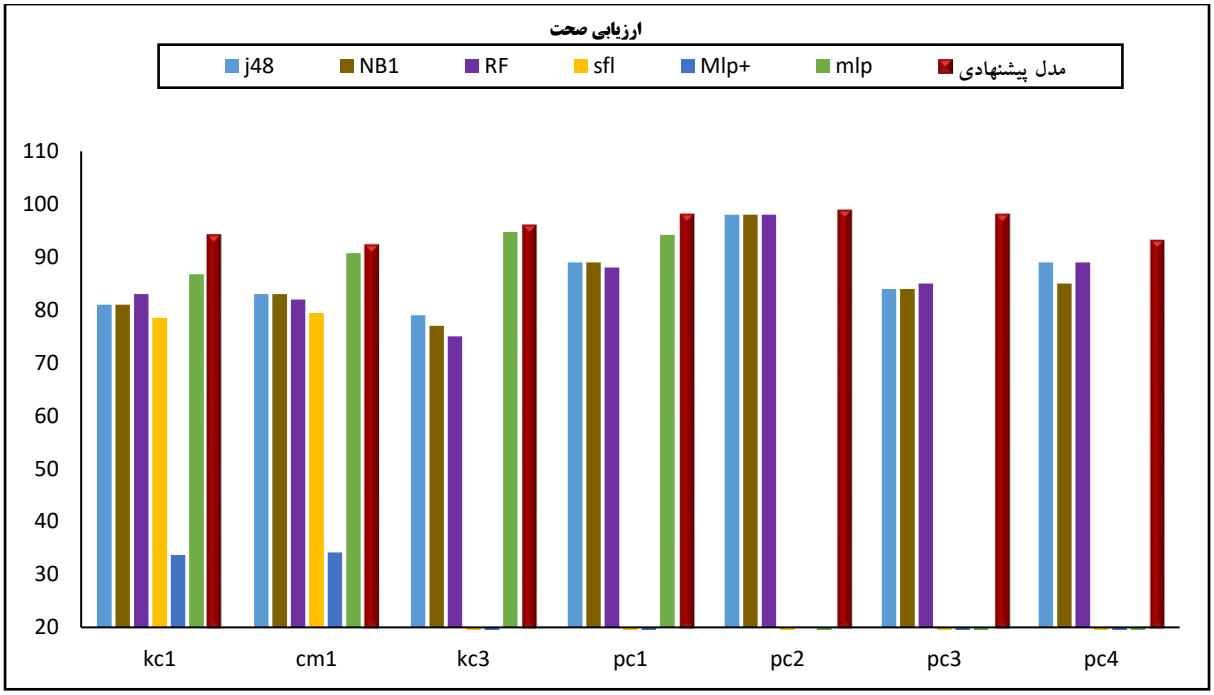

شکل ۶: ارزیابی مقدار معیار صحت در مقایسه با سایر روش ها

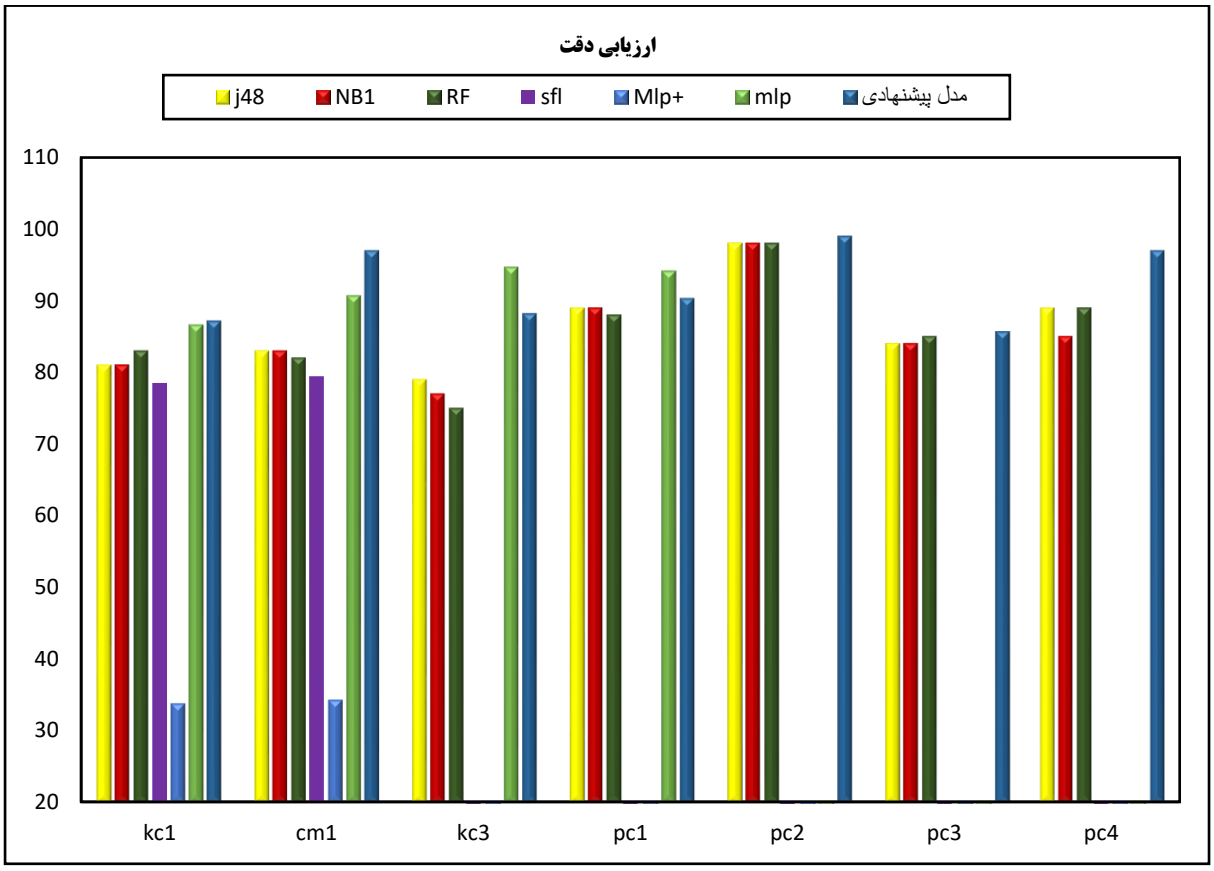

شکل ۷: ارزیابی مقدار معیار دقت در مقایسه با سایر روشها

مراجع

[1] Ö. F. Arar, and K. Ayan, "Software defect prediction using cost-sensitive neural network". Applied Soft Computing, Vol. 33, August 2015,pp. 263-277.

[2] J. Cahill, J. M. Hogan, and R. Thomas, "Predicting fault-prone software modules with rank sum classification". in Software Engineering Conference (ASWEC), 2013 22nd Australian,IEEE,(2013)

[3] W. Han, H. Jiang, W. Li, and Y. Li, "A summary of software defect model. in Control and Automation (CA)", 2014 7th Conference on,IEEE,(2014)

[۴] مهسا عاشمی مجد و عباس رسولزادگان و زهرا قویدل یزدی" مروری نظام‌مند بر مدل‌سازی قابلیت اطمینان نرم‌افزار". مدل سازی در مهندسی، دوره ۱۵، شماره ۵۰، پاییز ۱۳۹۶، صفحه ۳۱۳-۲۸۵.

[5] T. M. Khoshgoftaar, and N. Seliya, "Comparative assessment of software quality classification techniques: An empirical case study". Empirical Software Engineering, Vol. 9,No.3, September 2004,pp. 229-257.

[6] P. He, B. Li, X. Liu, J. Chen, and Y. Ma, "An Empirical Study on Software Defect Prediction with a Simplified Metric Set", vol. 59. Wuhan University, Wuhan, March 2014,pp. 170-190.

[7] G. Czibula, Z. Marian, and I. G. Czibula, "Software defect prediction using relational association rule mining". Information Sciences, Vol. 264, April 2014,pp. 260-278.

[8] R. Malhotra, and A. Jain, "Fault prediction using statistical and machine learning methods for improving software quality", Journal of Information Processing Systems, Vol. 8,No.2, 2012,pp. 241-262.

[9] I. Gondra, "Applying machine learning to software fault-proneness prediction", Journal of Systems and Software, Vol. 81,No.2,February 2008,pp. 186-195.

[10] K. Dejaeger, T. Verbraken, and B. Baesens, "Toward comprehensible software fault prediction models using bayesian network classifiers", IEEE Transactions on Software Engineering, Vol. 39,No.2, February 2013,pp. 237-257.

[11] H. Lu, B. Cukic, and M. Culp, "Software defect prediction using semi-supervised learning with dimension reduction", Proceedings of the 27th IEEE/ACM International Conference on Automated Software Engineering,ACM,(2012).

[12] H. Wang, T. M. Khoshgoftaar, and N. Seliya, "How many software metrics should be selected for defect prediction?", Twenty-Fourth International FLAIRS Conference,(2011).

[13] F. Peters, T. Menzies, and A. Marcus, "Better cross company defect prediction", Mining Software Repositories (MSR), 2013 10th IEEE Working Conference on,IEEE,(2013).

[14] S. Wang, and X. Yao, "Using class imbalance learning for software defect prediction", IEEE Transactions on Reliability, Vol. 62,No.2, April 2013,pp. 434-443.

[15] Y. Ma, G. Luo, X. Zeng, and A. Chen, "Transfer learning for cross-company software defect prediction", Information and Software Technology, Vol. 54, No.3, April 2012, pp. 248-256.

[16] A. Paksoy, and M. Göktürk, "Information fusion with dempster-shafer evidence theory for software defect prediction", Procedia Computer Science, Vol. 3, March 2011, pp. 600-605.

[17] W. Tao, L. Weihua, S. Haobin, and L. Zun, "Software defect prediction based on classifiers ensemble", Journal of Information and Computational Science, Vol. 8,No.16, December 2011, pp. 4241-4254,.

[18] A. S. Haghighi, M. A. Dezfuli, and S. Fakhrahmad, "Applying mining schemes to software fault prediction: A proposed approach aimed at test cost reduction". in Proceedings of the World Congress on Engineering,(2012).

[19] A. Okutan, and O. T. Yıldız, "Software defect prediction using Bayesian networks", Empirical Software Engineering, Vol. 19,No.1,August 2014, pp. 154-181.

[20] T. M. Khoshgoftaar, K. Gao, and N. Seliya, "Attribute selection and imbalanced data: Problems in software defect prediction", in Tools with Artificial Intelligence (ICTAI), 2010 22nd IEEE International Conference on,IEEE,(2010).

[21] P. Zhang, and Y.-t. Chang, "Software fault prediction based on grey neural network", Natural Computation (ICNC), 2012 Eighth International Conference on,IEEE,(2012).

[22] F. S. Fazel, "A New Method to Predict the Software Fault Using Improved Genetic Algorithm", Bulletin de la Société Royale des Sciences de Liège, Vol. 85, 2016, pp. 187-202.

[23] K. Sheoran, P. Tomar, and R. Mishra, "Software Quality Prediction Model with the Aid of Advanced Neural Network with HCS", Procedia Computer Science, Vol. 92, 2016, pp. 418-424.

[24] A. Pal, H. Jain, and M. Kumar, "Optimizing Software Error Proneness Prediction Using Bird Mating Algorithm", Software Project Management for Distributed Computing, Springer, April 2017,p. 257-287.

[25] X. Rong, F. Li, and Z. Cui, "A model for software defect prediction using support vector machine based on CBA", International Journal of Intelligent Systems Technologies and Applications, Vol. 15,No.1, 2016, pp. 19-34.

[26] R. Malhotra and A. Khurana, "Analysis of Evolutionary Algorithms to Improve Software Defect Prediction",(2018).

[27] S. Saremi, S. Mirjalili, and A. Lewis, "Grasshopper optimisation algorithm: Theory and application", Advances in Engineering Software, Vol. 105, March 2017,pp. 30-47.

[28] R. D. Stutzke, and M. Crosstalk," Software estimating technology: A survey". Los. Alamitos, CA: IEEE Computer Society Press (1997).

[۲۹] سید بهرام بهشتی اول و وحید احمدیان و احسان درویشان، "شناسایی خسارت در سازه با استفاده از پردازش سیگنال و شبکه های عصبی مصنوعی"، نشریه مدل سازی در مهندسی، دوره ۱۶، شماره ۵۲، بهار ۱۳۹۷، صفحه ۲۱-۲۱.

[۳۰] حسین شریف زاده ونیما امجدی، "توزیع بهینه توان راکتیو با استفاده از الگوریتم بهینه‌سازی دسته ذرات"، نشریه مدل سازی در مهندسی، دوره ۴، شماره ۱۸، پاییز ۱۳۸۸، صفحه ۷۳-۶۷.

[31] I. Maleki, A. Ghaffari and M. Masdari, "A new approach for software cost estimation with hybrid genetic algorithm and ant colony optimization", International Journal of Innovation and Applied Studies, Vol. 5,No.1, January 2014, pp. 72 .

[32] V. K. Asari, "Training of a feedforward multiple-valued neural network by error backpropagation with a multilevel threshold function", IEEE Transactions on Neural Networks, Vol.12, No.6, November 2001, pp.1519-1521.

[33] A. Chug, and S. Dhall, "Software defect prediction using supervised learning algorithm and unsupervised learning algorithm",(2013).

[۳۴] سولماز فرشیدپور و فرشید کی نیا، "پیش بینی نقص نرم افزار با استفاده ازترکیب مدل شبکه های عصبی و الگوریتم فرااکتشافی جهش قورباغه ها "، اولین همایش ملی فناوری اطلاعات و شبکه های کامپیوتری دانشگاه پیام نور، طبس،۱۳۹۱.