



## ارائه الگوریتمی مؤثر برای یادگیری قوانین بر پایه خوشه‌بندی ترکیبی و محاسبات گرانولار

فرناز ماهان<sup>۱\*</sup>، صالح صلحی<sup>۲</sup>، سید میثم روضه‌خوانی<sup>۳</sup>، جعفر رزم‌آرا<sup>۴</sup>

\*نویسنده مسئول، دریافت: ۱۴۰۰/۱۱/۰۸، بازنگری: ۱۴۰۱/۰۵/۲۳، پذیرش: ۱۴۰۱/۰۹/۱۹ (تاریخ‌ها توسط نشریه وارد می‌شوند)

<sup>۱</sup> و <sup>۲</sup> گروه علوم کامپیوتر، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشگاه تبریز، تبریز، ایران

### چکیده

یادگیری قوانین، یکی از ابزارهای معروف در کاربردهای مختلف یادگیری ماشین و داده‌کاوی است که در سیستم‌های مبتنی بر قانون به کار برده می‌شود. امروزه با حجم انبوهی از داده‌ها، اطلاعات و دانش مواجه هستیم که برای کنترل چنین مقدار وسیعی از داده‌ها، نیاز به هوشمندسازی و ارائه الگوریتمی مؤثر وجود دارد. سیستم‌های مبتنی بر قانون در مسائل مختلف طبقه‌بندی و پیش‌بینی به کار برده می‌شوند. قوانین تصمیم‌گیری در سیستم‌های مبتنی بر قانون به صورت عبارتهای اگر-آن‌گاه بیان می‌شوند. چنین قوانینی قادر به بیان دانش ضمنی قابل‌فهم برای انسان از مجموعه داده‌های حجیم هستند. یادگیری قوانین، عبارت از اضافه کردن قانون، توسعه قانون و ایجاد تطبیق‌پذیری در قانون از روی داده‌ها است. در این مقاله، الگوریتم جدید یادگیری قوانین با استفاده از روش‌های خوشه‌بندی ترکیبی و محاسبات گرانولار ارائه شده است. در الگوریتم پیشنهادی، ابتدا مجموعه داده‌ها با استفاده از پنج الگوریتم، خوشه‌بندی می‌شوند سپس از بین نتایج آن‌ها به صورت ترکیبی بهترین خوشه انتخاب می‌شود. در الگوریتم ترکیبی قبل از انتخاب بهترین خوشه، نمونه داده‌ها با استفاده از نظریه ناهم‌واری که زیرمجموعه‌ای از محاسبات گرانولار است تبدیل به اطلاعات گرانولی می‌شوند. محاسبات گرانولار، توانایی پردازش داده‌هایی که به صورت نادقیق و مبهم هستند را دارند و همچنین بدون نیاز به اطلاعات اضافی از طرف کاربر موجب کاهش افزونگی در داده‌ها می‌شوند. پس از خوشه‌بندی، قوانین تصمیم‌گیری استخراج می‌شود و با استفاده از الگوریتم خوشه‌بندی فازی c-میانگین با روش حداقل مربعات خطا، عمل یادگیری انجام می‌گیرد. نتایج حاصل از الگوریتم، نشان‌دهنده افزایش دقت یادگیری، توانایی پردازش داده‌ها با مقادیر پیوسته و گسسته، مقادیر غیرقطعی، پردازش داده‌های نویزی و کاهش میزان خطا در مقایسه با دیگر روش‌ها بوده است.

**کلمات کلیدی:** یادگیری ماشین، یادگیری قوانین، محاسبات گرانولار، خوشه‌بندی فازی و خوشه‌بندی ترکیبی

ترتیب، مسائل با پیچیدگی‌های بزرگ به برخی مسائل قابل حل‌تر نگاشت پیدا می‌کنند [۸].

خوشه‌بندی ترکیبی نیز به دلیل استفاده از مزایای چند الگوریتم خوشه‌بندی به‌طور هم‌زمان، موجب افزایش دقت یادگیری شده است. برخلاف راهکارهای پیشین، روش پیشنهادی قادر به حفظ و بهبود ویژگی‌هایی از جمله دقت بالای یادگیری و توانایی پردازش داده‌ها با مقادیر گسسته و پیوسته را دارد. در واقع، این الگوریتم، ویژگی‌های حائز اهمیت در مسئله یادگیری قوانین را فراهم کرده است. الگوریتم پیشنهادی بر روی ده مجموعه داده، آزمایش شده است. نتایج حاصل از الگوریتم پیشنهادی و راهکارهای پیشین، بیانگر بهبود سرعت در الگوریتم پیشنهادی نسبت به روش‌های قبلی است. ادامه مقاله به‌صورت زیر سازماندهی شده است: در بخش ۲، ابتدا به مرور کارهای گذشته پرداخته می‌شود. سپس در بخش ۳، مسئله اصلی پژوهش، طرح می‌گردد و در نهایت راهکار ارائه‌شده برای حل مسئله به همراه جزئیات بیان شده و همچنین نتایج به‌دست‌آمده ارائه می‌گردد و در نهایت، نتیجه‌گیری کلی تحت عنوان آخرین بخش، مطرح می‌شود.

## ۲- راهکارهای گذشته

تصمیم‌گیری‌های مبتنی بر قوانین، یکی از معروف‌ترین و پرکاربردترین روش‌های طبقه‌بندی است که از تصمیم‌گیری‌های انسانی به شکل قابل فهم و کامل، پشتیبانی می‌کند [۹،۱۰]. به این ترتیب در ادامه، مروری بر انواع الگوریتم‌های یادگیری قوانین خواهیم داشت و خلاصه‌ای از معایب و مزایای هر یک از آنها را بیان خواهیم کرد.

### • یادگیری قوانین مبتنی بر نظریه نامواری

روش ریاضی نظریه مجموعه نامواری را ریاضیدان معروف به نام پاولاک در سال ۱۹۹۱ ابداع کرد. مجموعه نامواری با پردازش داده‌ها و حذف پارامترهای زائد، کوتاه‌ترین الگوریتم تصمیم‌گیری را به‌دست می‌آورد و با استفاده از آن، قوانین تصمیم‌گیری استخراج می‌شوند. مزیت این روش بر سایر روش‌های تصمیم‌گیری، سادگی آن و کاربرد آن در کاهش حجم اطلاعات با حذف پارامترهای غیرضروری است. علاوه بر این، در روش مجموعه نامواری با کاهش حجم اطلاعات از پیچیدگی داده‌ها کاسته شده و قوانین تصمیم‌گیری به‌راحتی تعیین می‌گردد و لذا در شرایط عدم قطعیت می‌توان به نتایجی با دقت نسبتاً بالا دست یافت [۱۱].

مفهوم نظریه مجموعه نامواری بر اساس این فرض بنا شده که هر عضو موجود در مجموعه جهانی U شامل اطلاعات مشخصی است که این اطلاعات با برخی از صفات Q توصیف می‌شود. این اطلاعات را می‌توان در جدول داده‌ها که در آن، هر یک از سطرها اشاره به اشیای مختلف و هر یک از ستون‌ها نشان‌دهنده یک ویژگی از آن شی است نشان داد. از این‌رو هر یک از خانه‌های این جدول توصیف مشخصی از شی مشخص شده در آن سطر را با استفاده از ویژگی تعریف شده در ستون مربوطه نشان می‌دهد. از عمده مزیت این الگوریتم، پردازش و استخراج قوانین مجموعه داده‌هایی است که در آنها ناسازگاری و ابهام وجود دارد اما در این الگوریتم از داده‌هایی که به‌صورت پیوسته مقداردهی شده‌اند نمی‌توان استفاده کرد.

معمولاً سیستم‌های مبتنی بر قانون برای تصمیم‌گیری در شرایط ساخت‌نیافته ارائه می‌شود و می‌تواند در مواردی به‌کار رود که تجربه و تخصص نیاز است. در سیستم‌های مطرح‌شده، معمولاً کسر کوچکی از اطلاعات کشف‌شده از داده‌ها، عملاً در عملکرد سیستم مفید و کارآمد هستند. با توجه به طبیعت پویای بیشتر محیط‌ها در دنیای واقعی، این موضوع اهمیت بیشتری پیدا می‌کند و موجب بررسی و بازیافت دقیق دانش استخراجی در طول زمان می‌شود. از این رو لازم است که در روند بازیافت دانش، قوانین مفید، مؤثر و دقیق، حفظ و به‌صورت پویا به‌روز گردد. برای تأمین اهداف بالا و تولید قوانین کارا در چنین سیستم‌هایی می‌توان از راهکار یادگیری قوانین استفاده کرد [۱،۲]. یادگیری قوانین عبارت است از اضافه کردن قانون، توسعه قانون و ایجاد تطبیق‌پذیری در قانون از روی داده‌ها [۳،۴،۵]. سیستم‌های مبتنی بر قانون در مسائل مختلف طبقه‌بندی داده‌ها و پیش‌بینی آن‌ها مورد استفاده قرار می‌گیرند. این سیستم‌ها در کشف دانش نهان از مجموعه داده‌های حجیم و پیچیده به‌صورت قابل فهم برای انسان کمک می‌کنند و همچنین موجب افزایش سرعت تجزیه و تحلیل داده‌ها می‌شوند. در این سیستم‌ها، پایگاه داده‌های بزرگ و پیچیده را به‌صورت عبارت‌های اگر-آن‌گاه بیان می‌کنند که به این عبارت‌ها قوانین گفته می‌شود. قوانین تصمیم از دو قسمت شرط و عمل تشکیل می‌شوند و زمانی اجرا می‌شوند که تمامی شرط‌ها قابل ارضا باشد. یک سیستم یادگیری قوانین ابتدا قوانین تصمیم را از مجموعه داده‌ها استخراج و سپس با استفاده از یک الگوریتم یادگیری قوانین، شروع به یادگیری می‌کند. یک الگوریتم مناسب یادگیری قوانین باید شامل ویژگی‌هایی از قبیل دقت بالا، تعداد قوانین کم و همچنین توانایی پردازش مجموعه داده‌های مختلف به‌طوری‌که با مقادیر حقیقی و صحیح مقداردهی شده باشند را داشته باشد.

سیستم‌های مبتنی بر قانون را می‌توان در عمل برای کشف دانش به کار برد که به معنای استخراج دانش یا اطلاعات کشف‌شده از داده‌ها است. در این زمینه، قوانین، مبانی قوانین و اصطلاحات قوانین به‌عنوان گرانول‌های اطلاعاتی دیده می‌شوند بنابراین، بر اساس تمامی ویژگی‌ها، گرانول‌های مربوطه تشکیل می‌شود و از طریق این گرانول‌ها قوانین مربوط به تصمیم‌گیری ایجاد می‌شود و در صورت شناسایی ویژگی‌های جدید، این قوانین به‌طور مداوم به‌روز می‌شوند [۶،۷].

در راهکارهای پیشین، تمامی معیارهای موردسنجش در مسئله یادگیری قوانین رعایت نشده است. معمولاً یکی از معیارها ناقص است یا اگر تمامی معیارها هم رعایت شده باشد، سرعت و دقت الگوریتم نسبت به الگوریتم‌های ارائه‌شده پایین است. در این تحقیق، الگوریتمی برای مسئله یادگیری قوانین بر پایه روش‌های خوشه‌بندی و محاسبات گرانولار معرفی شده است که نتایج مطلوب در بین روش‌های پیشین داشته است. استفاده از محاسبات گرانولار در سال‌های اخیر در مسائل هوشمندی با پیشرفت روزافزون همراه بوده است و امکان پردازش مجموعه داده‌هایی که به‌صورت نادقیق و مبهم هستند را به ارمغان آورده است.

آگاهی از اطلاعات، یک فعالیت ذاتی و فراگیر است که انسان‌ها با قصد درک بهتر از مسائل به انجام می‌رسانند. به‌طور خاص، اطلاعات گرانولاری با هدف تقسیم مسائل پیچیده به چند قسمت قابل مدیریت و دستیابی است. به این

یک روش جدید برای یادگیری قوانین در داده‌های جریانی<sup>۶</sup> ارائه شده است. الگوریتم یادگیری سریع قوانین، به این صورت است که ابتدا با یک مجموعه قوانین خالی و یک قانون پیش فرض شروع می‌شود. در این الگوریتم از نمونه داده‌های بدون برچسب و برچسب‌دار استفاده می‌شود [۱۴]. یک ساختار داده، حاوی اطلاعات موردنیاز برای طبقه‌بندی نمونه داده‌های تست است و آمار کافی برای توسعه یک قانون موردنیاز را دارد؛ جایی که مقدار اولیه  $L$  را صفر در نظر می‌گیریم. هر قانون تصمیم‌گیری، شامل دو قسمت ویژگی‌های شرطی و ویژگی تصمیم است. اگر همه ویژگی‌های شرطی یک قانون برای یک نمونه داده، درست باشد بنابراین آن نمونه داده با قانون مذکور، پوشش داده می‌شود. این الگوریتم از نظر دقت و سرعت یادگیری، بهتر از درخت تصمیم است ولی ممکن است با افزایش سریع تعداد قوانین مواجه شود.

#### • یادگیری قوانین مبتنی بر درخت تصمیم فازی

درخت تصمیم<sup>۷</sup> شیوه‌ای برای ارائه پایگاه قانون و در واقع یک روش بازنمایی دانش است. درخت تصمیم فراگیر، یکی از روش‌های استنتاج استقرایی با کاربرد وسیع و روشی برای تخمین توابع هدف گسسته است که تابع فراگیر با یک درخت تصمیم نمایش داده می‌شود. رویکرد درخت تصمیم در بسیاری از زمینه‌ها کاربرد دارد از جمله: شناسایی الگوها، طبقه‌بندی الگوها، کلاس‌بندی، سیستم‌های پشتیبان تصمیم‌گیری و سیستم‌های خبره [۱۵]. یکی از معایب درخت تصمیم، بی‌ثباتی آن است. درخت تصمیم با به‌وجود آمدن اندک اغتشاشی در داده آموزشی، همانند طبقه‌بندی‌کننده بی‌ثبات عمل می‌کند. ساختار درخت تصمیم با تغییر جزئی در مجموعه داده‌ها ممکن است به‌کلی دگرگون شود و در مواردی که تصمیم‌های رقمی یا عددی موردنیاز است این نوع درخت تصمیم غیرقابل استفاده می‌شود. جهت‌بمنظور غلبه بر این مشکل، بعضی از دانش‌پژوهان، درخت تصمیم فازی را ارائه کرده‌اند. از مزایای این رویکرد، توانایی تحلیل متغیرهای کلامی است که دانش حاصل از آن برای انسان از قابلیت درک بالایی برخوردار است. نیازداشتن به داده‌های دقیق، اولویت‌بندی استراتژی‌ها، تشکیل پایگاه‌داده با استفاده از ماتریس‌های رویکرد کلاسیک، حفظ ماهیت اصلی آنها و نیز بهینه‌سازی صفات دخیل در امر تدوین استراتژی با محاسبه آنتروپی، مزایای دیگر این روش هستند. معایب این رویکرد، انعطاف‌پذیر نبودن است؛ بدین معنی که برای یادگیری داده‌های جدید، ساختار درخت باید دوباره ایجاد شود.

#### • یادگیری قوانین مبتنی بر الگوریتم ترکیبی بهینه‌سازی ذرات و منطق فازی

بهینه‌سازی گروه ذرات، یکی از روش‌های بهینه‌سازی ابتکاری است که بر مبنای جمعیت و بر اساس قوانین احتمال، کار می‌کند. ایده اصلی این روش را ابتدا دکتر کندی و دکتر ابرهات در سال 1995 مطرح کردند که از رفتار دسته‌جمعی ماهی‌ها و پرندگان برای یافتن غذا الهام می‌گیرد. گروهی از پرندگان و ماهی‌ها در یک فضای تصادفی دنبال غذا می‌گردند و تنها یک تکه غذا وجود دارد و هیچ‌یک از پرندگان از محل غذا اطلاعی ندارد و فقط فاصله خود تا غذا را می‌داند. یکی از بهترین استراتژی‌ها دنبال کردن پرنده‌ای است

#### • یادگیری قوانین مبتنی بر الگوریتم ترکیبی خوشه‌بندی و درخت تصمیم

در این الگوریتم، یک مدل ترکیبی با استفاده از روش خوشه‌بندی و درخت تصمیم برای یادگیری قوانین معرفی شده است. این الگوریتم از خوشه‌بندی سلسله‌مراتبی به‌عنوان روش تجزیه و تحلیل خوشه‌ای استفاده کرده است. در تجزیه و تحلیل خوشه‌بندی سلسله‌مراتبی، از ماتریس فاصله برای خوشه‌بندی داده‌ها استفاده می‌شود. هدف از خوشه‌بندی، دسته‌بندی اشیایی است که مشابه یکدیگر هستند. در این نوع خوشه‌بندی، نیازی به تعیین مقدار اولیه تعداد خوشه‌ها نیست. خوشه‌بندی به این صورت انجام می‌شود که در ابتدا هر نمونه داده به‌عنوان یک خوشه در نظر گرفته می‌شود سپس هرکدام از خوشه‌ها بیشتر مشابه هم باشند با یکدیگر ادغام می‌شوند و به‌عنوان یک خوشه جدید در نظر گرفته می‌شوند. در این الگوریتم از معیار فاصله برای اندازه‌گیری شباهت استفاده شده است [۱۲]. الگوریتم ترکیبی موجب شده است تا دقت طبقه‌بندی بهتر از درخت تصمیم C4.5 باشد. در واقع از مزایای هر دو الگوریتم خوشه‌بندی و درخت تصمیم استفاده کرده است.

#### • الگوریتم یادگیری قوانین مبتنی بر خوشه‌بندی و محاسبات گرانولار

محاسبات گرانولار یک روش معتبر برای توصیف و حل مسائل است. ایده اصلی محاسبات گرانولار در بسیاری از زمینه‌ها از قبیل محاسبات نرم<sup>۱</sup>، داده‌کاوی و یادگیری ماشین به‌کار برده می‌شود. بدین ترتیب مجموعه‌های فازی، نظریه مجموعه‌ها<sup>۲</sup> و ترکیبی از این مجموعه‌ها زیرشاخه‌ای از محاسبات گرانولار است که توانایی پردازش داده‌هایی با مقادیر مبهم و نادقیق را دارند. امروزه استفاده از اطلاعات گرانولاری در زمینه هوش مصنوعی، یادگیری ماشین، داده‌کاوی مورد توجه همگان قرار گرفته است. در این مقاله از مسئله اطلاعات فازی گرانولی<sup>۳</sup> که اولین بار زاده ارائه کرد، استفاده شده است [۱۳]. در الگوریتم ترکیبی خوشه‌بندی و محاسبات گرانولار، ابتدا مجموعه داده‌ها به‌صورت خوشه‌بندی گرانولار، خوشه‌بندی می‌شوند سپس با استفاده از سیستم استنتاج فازی، قوانین فازی از خوشه‌ها استخراج می‌شوند. نتایج این الگوریتم، بهتر از روش معمول سیستم استنتاج فازی<sup>۴</sup> و خوشه‌بندی فازی است.

در این الگوریتم هر خوشه، شامل نمونه داده‌هایی است که متعلق به یک کلاس باشند. علاوه بر این، هر خوشه دارای وزن مختص خود است. مجموعه وزن‌ها برای محاسبه فاصله اقلیدسی<sup>۵</sup> در یک سطح معینی از گرانولار استفاده می‌شود. تابع فاصله استفاده‌شده در این الگوریتم یک متغیر وزن برای هر جهت از هر بعد در یک خوشه مورد استفاده قرار می‌دهد. عرض خوشه‌های حاصل ممکن است در جهات مختلف توسعه یابند. مجموعه وزن‌ها از فاصله نسبی هر خوشه با خوشه‌هایی از کلاس‌های دیگر محاسبه می‌شود [۱۳]. این روش بدون در نظر گرفتن تعداد خوشه‌ها عمل خوشه‌بندی را انجام می‌دهد همچنین میزان دقت این الگوریتم، بیشتر از روش فازی معمول است.

#### • یادگیری قوانین مبتنی بر الگوریتم سریع یادگیری در جریان داده

5 Euclidean distance  
6 Data streams  
7 Decision Tree

1 Soft computing  
2 Set theory  
3 fuzzy information granular  
4 fuzzy inference system

برخلاف خوشه‌بندی کلاسیک که هر نمونه ورودی متعلق به یک و فقط یک خوشه است و نمی‌تواند عضو دو خوشه یا بیشتر باشد، در خوشه‌بندی فازی، یک نمونه می‌تواند متعلق به بیش از یک خوشه باشد. در خوشه‌بندی فازی C\_ میانگین تعداد خوشه‌ها باید از اول مشخص باشد که به صورت تصادفی باید در نظر گرفته شود. استفاده از محاسبات گرانولار موجب می‌شود تا مجموعه داده‌هایی که به صورت غیرقطعی، نادقیق و مبهم هستند را مورد استفاده قرار داد. این الگوریتم موجب کاهش خطای محاسبه شده خوشه‌بندی نسبت به روش‌های قبل شده است.

جدول ۱.۲ مقایسه‌ای از مطالعات انجام شده در حوزه یادگیری قوانین که به صورت مفصل بیان شد را ارائه می‌دهد.

### ۳- راهکار پیشنهادی و نتایج علمی

یک سیستم یادگیری قوانین باید توانایی مدیریت داده‌های توزیع شده و داده‌کاو از داده‌های جاری را داشته باشد. به عبارتی باید داده‌ها (داده‌های بلادرنگ) را جمع‌آوری و پردازش کند و بتواند الگوها و روابط میان آنها را کشف کند تا این الگوهای کشف شده در توسعه قوانین مربوط به مدیریت بهتر تصمیم‌گیری مورد استفاده قرار گیرد [۱۹].

از سیستم‌های یادگیری قوانین، شش خصوصیت اصلی انتظار می‌رود [۲۰]:

۱. یادگیری سریع از داده‌های با حجم بالا (در یک دوره از یادگیری)
۲. تطبیق پذیری بالا در هنگام دریافت داده جدید، در حالت برخط

که به غذا نزدیک‌تر است. این تئوری، استراتژی اصلی الگوریتم است. در این روش، هریک از ذرات سعی می‌کنند به سمتی حرکت کنند که بهترین تجربه‌های فردی و گروهی در آن نقاط روی داده است. دو مشکل اصلی الگوریتم PSO استاندارد، افتادن در دام بهینگی محلی و پایین بودن سرعت همگرایی آن است [۱۶]. در PSO هر پرنده یک جواب ممکن در فضای مسئله است که ذره نامیده می‌شود. هر ذره دارای یک مقدار شایستگی است که توسط تابع 2 در PSO هر پرنده یک جواب ممکن در فضای مسئله است که ذره شایستگی مسئله محاسبه می‌شود. ذره‌ای که به جواب نزدیک‌تر باشد، شایستگی بیشتری دارد. این الگوریتم، ماهیت پیوسته‌ای دارد و در کاربردهای متعددی کارایی خود را اثبات کرده است [۱۷]. استفاده از توابع فازی، رفتار الگوریتم PSO استاندارد را به مراتب بهبود می‌بخشد و این امکان را برای الگوریتم PSO فراهم می‌کند که در مقابل موقعیت‌های غیرعادی، عکس‌العمل مناسبی نشان دهد. الگوریتم ترکیبی بهینه‌سازی ذرات فازی، مشکل اصلی الگوریتم بهینه‌سازی ذرات که یکی افتادن در دام بهینگی محلی و دیگری پایین بودن سرعت همگرایی است را از بین برده است. اما از توابع غیرخطی نمی‌توان در الگوریتم ارائه شده استفاده کرد. بنابراین برای غلبه بر این مشکل می‌توان از منطق فازی برای ارائه توابع غیرخطی جدید برای ضریب اینرسی و ضرایب شتاب استفاده کرد که منبای تصمیم‌گیری آن پارامترهای دیگری مثل سرعت فعلی ذره،  $c1$  و  $c2$  یا اعداد تصادفی باشد.

#### • الگوریتم یادگیری قوانین مبتنی بر خوشه‌بندی فازی

در این الگوریتم از خوشه‌بندی فازی C\_ میانگین با یک روش جدید گرانولی استفاده شده است. الگوریتم خوشه‌بندی فازی C\_ میانگین را ابتدا دان<sup>۱</sup> در سال 1973 بررسی کرد و سپس بزک<sup>۲</sup> در سال 1974 توسعه داد [۱۸].

جدول ۱.۲: مقایسه الگوریتم‌های یادگیری قوانین

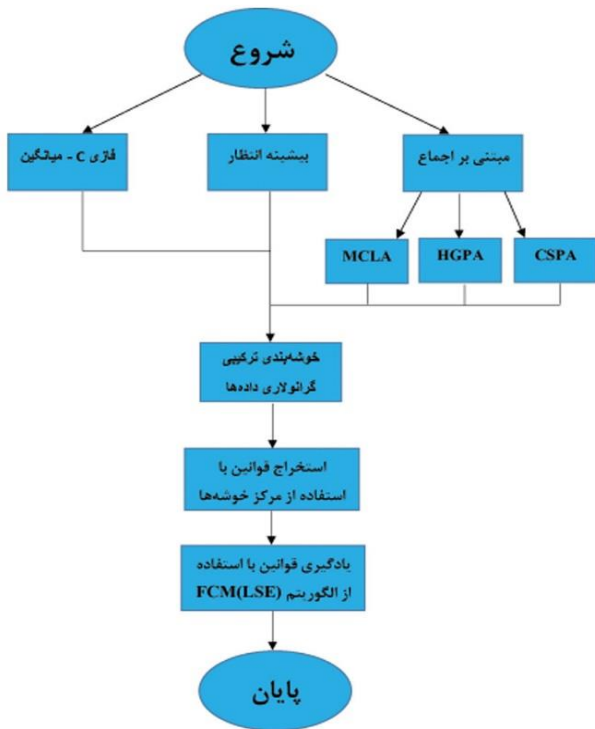
نام الگوریتم	مزایا	معایب	توانایی پردازش داده‌هایی با معادیر نادقیق و غیر قطعی	توانایی پردازش داده‌های نویزی
مجموعه‌های نامموزی	توانایی پردازش داده‌ها با معادیر مبهم و نادقیق - توانایی استخراج ویژگی	عدم توانایی پردازش داده‌ها با معادیر پیوسته	✓	✓
الگوریتم ترکیبی خوشه‌بندی و درخت تصمیم	سرعت و دقت زیاد از درخت تصمیم رایج	عدم استفاده در کاربردهای مختلف	-	-
الگوریتم ترکیبی خوشه‌بندی و محاسبات گرانولار	توانایی پردازش داده‌ها با معادیر مبهم و نادقیق - توانایی استخراج ویژگی	-	✓	✓
الگوریتم سریع یادگیری	سرعت و دقت زیاد از درخت تصمیم رایج	افزایش تعداد قوانین	-	-
درخت تصمیم فازی	سرعت و دقت زیاد توانایی درک بالا	انعطاف‌پذیری پایین	✓	-
الگوریتم ترکیبی ازدحام ذرات و منطق فازی	رفع مشکل اصلی افتادن در دام بهینگی محلی	عدم توانایی استفاده از توابع غیرخطی	✓	-
الگوریتم خوشه‌بندی فازی با کمترین مربعات خطا	دقت زیاد از الگوریتم خوشه‌بندی فازی رایج	-	✓	-

✓: الگوریتم این ویژگی را دارد.

-: الگوریتم این ویژگی را ندارد.

۶. قدرت برخورد با انواع مختلف دانش (مانند قوانین، احتمالات و غیره)، تجزیه و تحلیل خطا و موفقیت بر اساس رفتار سیستم و ایجاد تصمیم.

۳. داشتن ساختار باز برای اضافه کردن ویژگی و پارامتر جدید در هر مرحله از عملکرد سیستم
۴. ذخیره داده‌های دریافتی برای تجزیه و تحلیل
۵. یادگیری و بهبود در حین عملکرد سیستم



شکل ۱.۳. مراحل انجام کار الگوریتم پیشنهادی

الگوریتم ترکیبی، ابتدا خوشه‌ای را انتخاب می‌کند که تعداد نمونه داده‌ها در آن خوشه، بیشترین باشد. به همین ترتیب خوشه‌های بعدی را انتخاب و هر بار نمونه داده‌های تکراری در خوشه‌ها را حذف می‌کند تا هر نمونه داده تنها در یک خوشه قرار بگیرد بنابراین الگوریتم ترکیبی به این صورت معرفی می‌گردد:

الگوریتم خوشه‌بندی ترکیبی، از سه نوع خوشه‌بندی مبتنی بر اجماع، خوشه‌بندی بیشینه انتظار و فازی C- میانگین استفاده کرده است. ابتدا مجموعه داده‌ها را با هر یک از الگوریتم‌های بیان شده خوشه‌بندی می‌کند. نتایج هر الگوریتم با یکدیگر به این صورت ارزیابی می‌شود که ابتدا الگوریتمی انتخاب می‌گردد که میزان شباهت خوشه‌های آن به چهار الگوریتم دیگر، بیشتر از بقیه باشد. پس از انتخاب الگوریتم از بین خوشه‌های آن، خوشه‌ای را انتخاب می‌کند که تعداد نمونه داده‌ها در آن بیشتر از تعداد نمونه داده‌ها در خوشه‌های دیگر باشد. خوشه انتخاب شده، به عنوان اولین خوشه در الگوریتم ترکیبی پیشنهادی در نظر گرفته می‌شود. پس از انتخاب اولین خوشه، نمونه داده‌هایی که در داخل آن خوشه وجود دارند از همه خوشه‌های باقی‌مانده حذف می‌شوند تا نمونه داده‌ای تکراری وجود نداشته باشد. این کار تا زمانی ادامه می‌یابد که همه نمونه‌ها در خروجی الگوریتم وجود داشته باشند و تعداد خوشه‌ها برابر تعداد خوشه در نظر گرفته شده باشد [۲۱].

در الگوریتم پیشنهادی، از نظریه ناهمواری برای گرانولی کردن نمونه داده‌ها استفاده شده است. نظریه ناهمواری، زیرمجموعه‌ای از محاسبات گرانولار است که در نمونه داده‌های آن عدم قطعیت و ابهام وجود دارد [۲۲].

شکل‌های ۲.۳، ۳.۳، ۴.۳، ۵.۳ و ۶.۳ را در نظر بگیرید:

تاکنون روش‌های متعددی در راستای مسئله یادگیری قوانین ارائه شده است. در بخش قبلی تعدادی از راهکارهای پیشین، مورد بررسی قرار گرفت. با توجه به نتایج و مزایای الگوریتم‌های ترکیبی می‌توان ادعا کرد که استفاده از روش‌های ترکیبی، نتایج مطلوبی را به همراه داشته‌اند [۲۱] زیرا از ویژگی‌های چند الگوریتم به طور هم‌زمان می‌توان استفاده کرد. با توجه به این مسئله در این مقاله، یک روش جدید مبتنی بر خوشه‌بندی و محاسبات گرانولار برای حل مسئله یادگیری قوانین ارائه شده است. ساختار خوشه‌بندی معرفی شده به صورت ترکیبی از الگوریتم‌های خوشه‌بندی EM، HGPA، CSPA، MCLA و FGM تشکیل شده است. الگوریتم جدید با نام الگوریتم خوشه‌بندی ترکیبی گرانولی<sup>۱</sup> (HIGCRL) برای مسئله یادگیری قوانین معرفی شده است.

### ۱-۳- راهکار پیشنهادی

الگوریتم پیشنهادی، توانایی پردازش مجموعه داده‌ها در محیط گسسته و پیوسته را دارد و همچنین موجب افزایش دقت یادگیری شده است. در این بخش، الگوریتم پیشنهادی به طور کامل معرفی می‌گردد و با الگوریتم‌های پیشین ارزیابی و مقایسه می‌شود. مراحل الگوریتم پیشنهادی در شکل ۱.۳ نشان داده شده است.

در این الگوریتم، ابتدا مجموعه داده‌ها با الگوریتم‌های فازی C- میانگین، بیشینه انتظار و الگوریتم‌های مبتنی بر اجماع، خوشه‌بندی می‌شوند. این نوع خوشه‌بندی که به خوشه‌بندی ترکیبی معروف است به این صورت است که پس از خوشه‌بندی مجموعه داده‌ها نتایج هر خوشه به صورت جداگانه بررسی می‌شود.

## ۲-۳- ارزیابی و نتایج عملی

در این بخش، به ارزیابی نتایج عملی به‌دست‌آمده از الگوریتم پیشنهادی می‌پردازیم. برای این منظور روش معرفی‌شده بر روی مجموعه داده‌های یادگیری ماشین که با مقادیر حقیقی و صحیح مقداردهی شده‌اند، اجرا می‌شود [۲۳]. در نهایت نتایج به‌دست‌آمده از الگوریتم پیشنهادی و نتایج الگوریتم‌های پیشین مقایسه می‌شوند. برای خوشه‌بندی پایه در الگوریتم‌های ترکیبی CSPA، MCLA و HGPA از الگوریتم خوشه‌بندی  $K$ - میانگین استفاده شده است. بنابراین الگوریتم‌های خوشه‌بندی را 15 بار روی الگوریتم  $K$ - میانگین با تعداد خوشه تصادفی بین 2 تا  $\sqrt{N}$  انتخاب شده است، اجرا شده است به طوری که  $K$  تعداد خوشه و  $N$  تعداد نمونه داده‌ها را نشان می‌دهد.

جدول ۱.۳: معرفی مجموعه داده‌ها

نام مجموعه داده	کاربرد	تعداد ویژگی	تعداد نمونه	نوع مقادیر مجموعه داده
Pima	تشخیص بیماری دیابت	۸	۷۶۸	حقیقی و صحیح
Servo	تشخیص سیستم‌های سروو	۴	۱۶۷	طبقه‌بندی و حقیقی
Housing	تشخیص خانه	۱۳	۵۰۶	حقیقی و صحیح
Biodegradation	توصیف مولکول	۴۱	۱۰۵۵	حقیقی و صحیح
Balancescale	روان‌پزشکی	۴	۶۲۵	طبقه‌بندی
Bupa	تشخیص بیماری کبد	۷	۳۴۵	طبقه‌بندی
Haberman	بقایای بیماران سرطانی	۳	۳۰۶	صحیح


### • ارزیابی

در این بخش، نتایج آزمایش‌ها بر روی مجموعه داده‌های معروف یادگیری ماشین [۲۳] انجام گرفته که ویژگی‌های آن‌ها در جدول ۱.۳ بیان شده است.


### • مقایسه

در این بخش، نتایج به‌دست‌آمده از الگوریتم HIGCRL با الگوریتم‌های پیشین مقایسه شده است به طوری که مجموعه داده‌ها به دو قسمت نمونه‌های آموزشی و نمونه‌های آزمایشی تقسیم می‌شود و سپس آزمایش‌ها بر روی آن‌ها انجام می‌گیرد. ۷۰ درصد نمونه‌ها به‌عنوان نمونه‌های آموزشی و ۳۰ درصد به‌عنوان نمونه آزمایشی در نظر گرفته شده است. تعداد تکرار الگوریتم در این آزمایش‌ها 30 در نظر گرفته شده و در نهایت میانگین ۳۰ تکرار به‌عنوان خروجی الگوریتم در جداول ۲.۳، ۳.۳، ۴.۳، ۵.۳، ۶.۳، ۷.۳، ۸.۳، ۹.۳، ۱۰.۳، ۱۱.۳، ۱۲.۳، ۱۳.۳، ۱۴.۳، ۱۵.۳، ۱۶.۳، ۱۷.۳، ۱۸.۳، ۱۹.۳، ۲۰.۳ و ۲۱.۳ مطرح شده است. همچنین میزان دقت الگوریتم پیشنهادی با الگوریتم ارائه‌شده [۲۴] در جدول ۲۲.۳ با تعداد خوشه ۲ بر روی مجموعه داده‌های Pima، Bupa و Haberman مقایسه شده است. الگوریتم پیشنهادی ترکیبی از پنج الگوریتم خوشه‌بندی تشکیل شده است. در روش پیشین الگوریتم ترکیبی به‌صورت جداگانه با الگوریتم‌های خوشه‌بندی مبتنی بر اجماع و بیشینه انتظار مقایسه شده است. نتایج حاصل، بیانگر بهبود دقت الگوریتم ترکیبی را نشان می‌دهد [۲۵].


در این مقاله الگوریتم فازی  $C$ -میانگین با روش کم‌ترین مربعات خطا را به الگوریتم ترکیبی اضافه کرده و نتایج آن مقایسه شده است. به این ترتیب برای انجام آزمایش‌ها میزان خطای الگوریتم‌ها با استفاده از روش کم‌ترین مربعات




شکل ۳.۳: خوشه‌بندی مبتنی بر اجماع MCLA




شکل ۲.۳: خوشه‌بندی مبتنی بر اجماع CSPA




شکل ۵.۳: خوشه‌بندی فازی  $C$ - میانگین



شکل ۴.۳: خوشه‌بندی مبتنی بر اجماع HGPA



شکل ۷.۳: شکل نهایی خوشه‌ها



شکل ۶.۳: خوشه‌بندی بیشینه انتظار

از بین خوشه‌بندی‌هایی موجود در شکل‌های ۲.۳، ۳.۳، ۴.۳، ۵.۳ و ۶.۳ خوشه‌بندی CSPA به‌عنوان بهترین خوشه‌بندی انتخاب شده است زیرا خوشه‌های آن، بیشترین شباهت را با دیگر خوشه‌ها دارد و از بین خوشه‌های آن به دلیل وجود تراکم زیاد در بین داده‌های آن خوشه به رنگ مشکی به‌عنوان اولین خوشه در الگوریتم ترکیبی در نظر گرفته می‌شود.

پس از انجام عمل خوشه‌بندی بر روی مجموعه داده‌ها مرحله استخراج قوانین به این صورت است که مرکز هر خوشه به‌عنوان یک قانون از هر خوشه استخراج می‌شود به طوری که هر خوشه به‌صورت یک قانون نشان داده می‌شود. سپس این قوانین برای یادگیری به‌عنوان ورودی الگوریتم فازی  $C$ -میانگین در نظر گرفته می‌شوند. در شکل ۷.۳ نقاط قرمز رنگ به‌عنوان مرکز خوشه‌های محاسبه شده است در نظر گرفته می‌شوند که هر مرکز بیانگر یک قانون تصمیم‌گیری است. در الگوریتم پیشنهادی، تعداد قوانین برابر با تعداد خوشه‌ها است.

برای مثال یک قانون استخراج شده می‌تواند به‌صورت زیر مقداردهی شود:

$$IF \ x_1 = 10 \ \text{and} \ x_2 = 5.5 \ \text{and} \ x_3 = 8 \ \text{then} \ y = 1$$

به‌منظور یادگیری قوانین، از الگوریتم فازی  $C$ -میانگین استفاده شده است. این الگوریتم برای محاسبه نرخ خطا، از روش کم‌ترین مربعات خطا استفاده کرده است.

در بخش بعدی، نتایج حاصل از ۵ الگوریتم FCM، MCLA، HGPA، CSPa، EM و نشان داده می‌شود. در این تحقیق علاوه بر الگوریتم پیشنهادی برای مسئله یادگیری قوانین از الگوریتم‌های FCM، MCLA، HGPA، CSPa و EM برای یادگیری قوانین که تا به حال ارائه نشده بود، استفاده شده است. نتایج حاصل از الگوریتم‌ها به تفصیل بیان شده است.

خطا محاسبه می‌شود. همچنین تعداد خوشه‌ها در این الگوریتم به صورت تصادفی انتخاب شده است. میزان فازی بودن نتایج حاصل از خوشه‌ها با مقادیر ۲، ۲.۵ و ۲.۹ در نظر گرفته شده است که هر چه مقدار این عدد بیشتر باشد میزان فازی بودن نتیجه خروجی نیز بیشتر می‌شود. متغیر C تعداد خوشه‌ها و m میزان فازی بودن نتایج حاصل از خوشه‌بندی را نشان می‌دهد.

جدول ۲.۳: میزان خطای مجموعه داده Pima

نام الگوریتم	C	خطای نمونه‌های آموزشی m = 2	خطای نمونه‌های آزمایشی m = 2	خطای نمونه‌های آموزشی m = 2.5	خطای نمونه‌های آزمایشی m = 2.5	خطای نمونه‌های آموزشی m = 2.9	خطای نمونه‌های آزمایشی m = 2.9
FCM	۱۰	۰.۲۲۱۳۸	۰.۲۱۹۷۵	۰.۲۲۱۲۶	۰.۲۱۸۸۷	۰.۲۲۲۱۸	۰.۲۲۲۱۸
HIGCRL	۱۰	۰.۲۱۹۴۹	۰.۲۲۰۱۶	۰.۲۱۷۸۶	۰.۲۱۸۸۷	۰.۲۱۸۲	۰.۲۱۸۲
FCM	۹	۰.۲۲۲۶۷	۰.۲۱۸۶۲	۰.۲۲۰۷۲	۰.۲۱۷۹۷	۰.۲۲۳۴۸	۰.۲۲۳۴۸
HIGCRL	۹	۰.۲۲۰۴۱	۰.۲۱۸۹۵	۰.۲۱۹۳۶	۰.۲۱۸۳۹	۰.۲۱۸۷۱	۰.۲۱۸۷۱
FCM	۸	۰.۲۲۱۶۸	۰.۲۱۸۴۱	۰.۲۲۲۴۹	۰.۲۲۱۵	۰.۲۲۱۶۵	۰.۲۲۱۶۵
HIGCRL	۸	۰.۲۲۰۵۲	۰.۲۱۸۹۹	۰.۲۲۰۳۳	۰.۲۱۷۶۳	۰.۲۱۷۳۲	۰.۲۱۷۳۲
FCM	۷	۰.۲۲۳۶۸	۰.۲۱۸۱۵	۰.۲۲۵۳۸	۰.۲۲۲۰۴	۰.۲۲۱۹۸	۰.۲۲۱۹۸
HIGCRL	۷	۰.۲۲۲۲۲	۰.۲۱۸۹۹	۰.۲۲۰۷۶	۰.۲۱۷۷۵	۰.۲۱۷۶۲	۰.۲۱۷۶۲
FCM	۶	۰.۲۲۲۱۶	۰.۲۲	۰.۲۲۵۵۳	۰.۲۲۱۴۶	۰.۲۲۲	۰.۲۲۲
HIGCRL	۶	۰.۲۲۲۰۴	۰.۲۱۸۵۷	۰.۲۲۲۲۹	۰.۲۱۹۱۹	۰.۲۱۸۱۹	۰.۲۱۸۱۹
FCM	۵	۰.۲۲۲۷۳	۰.۲۱۹۷۵	۰.۲۲۵۵۱	۰.۲۲۲۷۸	۰.۲۲۲۷۶	۰.۲۲۲۷۶
HIGCRL	۵	۰.۲۲۳۴۶	۰.۲۱۹۲۸	۰.۲۲۲۲۵	۰.۲۲۲۲۹	۰.۲۲۲۸۲	۰.۲۲۲۸۲
FCM	۴	۰.۲۲۷۴۹	۰.۲۲۰۶۲	۰.۲۲۸۴	۰.۲۲۰۵۶	۰.۲۲۰۵۵	۰.۲۲۰۵۵
HIGCRL	۴	۰.۲۲۵۲۲	۰.۲۱۹۴۶	۰.۲۲۵۱۵	۰.۲۲۰۱۶	۰.۲۱۸۸۳	۰.۲۱۸۸۳
FCM	۳	۰.۲۲۹۱۱	۰.۲۲۲۴۲	۰.۲۲۹۳۵	۰.۲۲۲۱۱	۰.۲۲۱۹۴	۰.۲۲۱۹۴
HIGCRL	۳	۰.۲۲۷۷۸	۰.۲۲۱۰۳	۰.۲۲۶۵۹	۰.۲۱۹۲۹	۰.۲۱۹۷۸	۰.۲۱۹۷۸
FCM	۲	۰.۲۲۹۵۲	۰.۲۲۱۱	۰.۲۲۹۵۷	۰.۲۲۱۱۳	۰.۲۲۱۱۴	۰.۲۲۱۱۴
HIGCRL	۲	۰.۲۲۹۰۵	۰.۲۲۱۲	۰.۲۲۹۴	۰.۲۲۱۱۸	۰.۲۲۱۱۲۶	۰.۲۲۱۱۲۶

جدول ۳.۳: میزان خطای مجموعه داده Servo

نام الگوریتم	C	خطای نمونه‌های آموزشی m = 2	خطای نمونه‌های آزمایشی m = 2	خطای نمونه‌های آموزشی m = 2.5	خطای نمونه‌های آزمایشی m = 2.5	خطای نمونه‌های آموزشی m = 2.9	خطای نمونه‌های آزمایشی m = 2.9
FCM	۱۰	۱.۴۰۳۵۸	۲.۶۷۵۴۵	۱.۸۷۲۲۸	۲.۲۹۶۱۱	۱.۸۳۳۲۱	۹.۷۶۶۱۴
HIGCRL	۱۰	۱.۴۴۱۸۱	۲.۶۳۴۴۷	۱.۶۶۴۴۹	۲.۰۶۵۷۱	۱.۸۲۹۵۵	۲.۲۴۱۲۸
FCM	۹	۱.۳۹۰۵۵	۲.۷۷۲۵۳	۱.۸۹۶۲۵	۲.۳۸۰۴۲	۱.۸۶۸۷۸	۵.۱۸۲۸۷
HIGCRL	۹	۱.۴۲۲۸۵	۲.۶۱۲۲۵	۱.۷۲۷۳۶	۲.۲۲۳۵۷	۱.۸۱۱۲۱	۲.۱۹۶۶۶
FCM	۸	۱.۲۶۸۶۱	۲.۶۹۵۱۶	۱.۸۸۶۲۶	۲.۳۸۷۲۶	۱.۸۹۵	۳.۳۷۲۳۴
HIGCRL	۸	۱.۴۵۵۶۱	۲.۶۶۲۳۶	۱.۷۲۳۷۷	۲.۲۰۲۲۷	۱.۸۴۸۴	۲.۲۱۳۶۹
FCM	۷	۱.۵۲۲۱	۲.۷۲۱۷۴	۱.۹۰۵۷۱	۲.۳۵۱۹۵	۱.۹۱۴۱۲	۳.۱۴۳۱۲
HIGCRL	۷	۱.۴۶۸۳۲	۲.۶۶۴۰۱	۱.۷۵۷۳۹	۲.۲۲۹۳۶	۱.۸۳۲۹۷	۲.۲۴۰۸
FCM	۶	۱.۵۱۵۴۲	۲.۷۰۷۸۶	۱.۸۷۷۴۲	۲.۲۸۵۶۸	۱.۹۳۳۴۴	۲.۵۹۹۶۸
HIGCRL	۶	۱.۴۷۴۷۹	۲.۷۰۰۰۳	۱.۸۰۲۷۴	۲.۲۳۴۳۶	۱.۸۶۶۵۶	۲.۲۴۹۷۳
FCM	۵	۱.۵۱۷۲۸	۲.۷۳۶۸۶	۱.۹۰۷۷۵	۲.۳۱۹۲۶	۱.۹۲۷۲۵	۲.۳۷۱۶
HIGCRL	۵	۱.۵۰۲۴	۲.۷۳۴۵۵	۱.۸۲۷۳	۲.۲۵۵۶۲	۱.۸۴۵۷۴	۲.۲۶۵۲۹
FCM	۴	۱.۵۵۷۱۱	۲.۷۹۰۲۴	۱.۹۰۴۹۴	۲.۳۳۹۸۷	۱.۹۱۳۱۳	۲.۳۸۸۲۸
HIGCRL	۴	۱.۵۴۲۴۴	۲.۷۹۷۸	۱.۸۵۸۱۶	۲.۲۸۶۱۱	۱.۸۷۱۰۷	۲.۲۷۸۸۴
FCM	۳	۱.۶۱۱۳۶	۲.۹۳۲۲۵	۱.۹۷۰۰۴	۲.۳۲۴۰۹	۱.۹۴۶۱۵	۲.۳۷۱۰۳
HIGCRL	۳	۱.۵۷۲۸۶	۲.۸۴۶۱۷	۱.۹۱۴۱۵	۲.۳۳۴۹۲	۱.۹۲۸۳۳	۲.۳۴۴۳۶
FCM	۲	۱.۵۸۹۶۴	۲.۹۰۴۵۸	۲.۰۱۷۸۴	۲.۴۵۵۸۹	۲.۰۵۷۸۹	۲.۶۲۲۵۳
HIGCRL	۲	۱.۷۰۳۰۷	۲.۹۷۴۲۲	۲.۰۳۷۰۳	۲.۴۵۲۰۲	۲.۰۰۹۳۵	۲.۴۲۸۳۹

جدول ۴.۳: میزان خطای مجموعه داده Housing

نام الگوریتم	C	خطای نمونه‌های آموزشی	خطای نمونه‌های آزمایشی	خطای نمونه‌های آموزشی	خطای نمونه‌های آزمایشی	خطای نمونه‌های آموزشی	خطای نمونه‌های آزمایشی
		$m = 2$	$m = 2$	$m = 2.5$	$m = 2.5$	$m = 2.9$	$m = 2.9$
FCM	۱۰	۶۷.۶۶۰۴۴	۵۴.۳۹۱۲۲	۶۸.۶۹۱۱۲	۵۴.۰۴۰۱	۶۹.۱۷۲۴۵	۵۴.۲۲۶۳۴
HIGCRL	۱۰	۶۵.۵۵۴۴۴	۵۳.۱۸۶۰۲	۶۵.۷۷۶	۵۳.۱۷۳۶۸	۶۵.۹۳۷۸۹	۵۴.۰۹۸۸۶
FCM	۹	۶۸.۱۸۵۶۵	۵۴.۳۳۷۵۲	۶۹.۰۱۸۳۸	۵۴.۶۰۲۵۳	۶۹.۵۵۱۰۷	۵۴.۴۹۸۴۳
HIGCRL	۹	۶۶.۴۸۱۱۴	۵۳.۱۳۵۹۷	۶۶.۸۹۳۵	۵۴.۲۹۱۳۳	۶۶.۷۳۸۷۷	۵۴.۲۰۵۹۳
FCM	۸	۶۸.۲۲۸۷۵	۵۴.۱۳۰۷۲	۶۹.۴۸۴۵۸	۵۴.۶۵۹۷۲	۶۹.۹۱۴۳۶	۵۴.۹۰۱۷۵
HIGCRL	۸	۶۶.۵۶۹۹۴	۵۳.۲۵۷۴۲	۶۷.۵۷۵۴۶	۵۴.۸۸۳۷	۶۷.۱۶۱۱۵	۵۴.۳۴۳۹۸
FCM	۷	۶۸.۴۱۹۵	۵۳.۶۲۹۴۵	۶۹.۴۸۲۴۲	۵۴.۴۴۱۷۵	۷۰.۱۲۶۱۵	۵۵.۰۹۰۳۴
HIGCRL	۷	۶۷.۷۳۱۶۹	۵۳.۱۱۴۳۵	۶۸.۳۱۴۸۸	۵۵.۲۳۶۷۵	۶۸.۶۰۸۶۴	۵۵.۰۱۴۱۱
FCM	۶	۶۸.۵۱۴۲۵	۵۳.۸۲۵۷۹	۶۹.۶۵۲۶۱	۵۳.۹۵۱۶۷	۷۰.۰۵۷۴۱	۵۴.۲۶۵۱۶
HIGCRL	۶	۶۸.۹۳۶۱۴	۵۵.۸۵۶۸۵	۶۸.۵۳۲۱۵	۵۴.۹۱۵۵۸	۶۹.۰۴۸۰۶	۵۵.۴۴۱۴۶
FCM	۵	۶۸.۲۸۱۲۴	۵۴.۱۷۵۴۸	۶۸.۸۳۵۱۹	۵۴.۶۶۰۴۷	۶۸.۸۵۳۱۷	۵۵.۱۸۱۳۹
HIGCRL	۵	۶۹.۷۵۱۹۷	۵۵.۸۵۴۹۲	۷۰.۰۱۷۵	۵۶.۸۷۲۸۲	۷۰.۵۱۹۷۷	۵۷.۵۱۱۶۸
FCM	۴	۷۱.۴۸۴۳۹	۵۴.۸۶۷۲۸	۷۲.۳۳۷۱۱	۵۶.۳۴۳۷۵	۷۳.۶۳۸۵۲	۵۸.۷۱۴۶۶
HIGCRL	۴	۷۱.۶۵۶۳۲	۵۵.۲۵۴۸۱	۷۲.۳۷۴۸۱	۵۶.۸۸۶۳۷	۷۲.۵۲۳۹۷	۵۷.۹۰۸۶۱
FCM	۳	۷۴.۲۶۲۰۵	۵۷.۴۵۷۷۴	۷۵.۶۱۵۰۱	۵۹.۲۲۰۰۷	۷۶.۳۷۸۷	۶۰.۰۸۵۸۵
HIGCRL	۳	۷۳.۳۹۰۹۸	۵۶.۶۷۷۰۴	۷۳.۷۸۱۳۹	۵۷.۳۹۳۱	۷۳.۹۵۳۰۴	۵۷.۸۸۰۸۱
FCM	۲	۷۴.۳۴۴۸۶	۵۷.۵۹۰۳۴	۷۵.۱۷۴۴۳	۵۸.۲۹۷۰۸	۷۵.۷۸۷۵۵	۵۸.۷۸۲۴۴
HIGCRL	۲	۷۴.۲۷۴۹۹	۵۷.۴۹۲۵۷	۷۴.۷۹۸۲۶	۵۷.۹۰۳۹۵	۷۵.۲۱۲۶۴	۵۸.۱۹۸۴۸

جدول ۵.۳: میزان خطای مجموعه داده Biodegration

نام الگوریتم	C	خطای نمونه‌های آموزشی	خطای نمونه‌های آزمایشی	خطای نمونه‌های آموزشی	خطای نمونه‌های آزمایشی	خطای نمونه‌های آموزشی	خطای نمونه‌های آزمایشی
		$m = 2$	$m = 2$	$m = 2.5$	$m = 2.5$	$m = 2.9$	$m = 2.9$
FCM	۱۰	۰.۱۸۱۸۱	۰.۱۸۰۶۴	۰.۱۸۵۱	۰.۱۸۲۶۶	۰.۱۸۶۷۷۴	۰.۱۹۰۳۷۴
HIGCRL	۱۰	۰.۱۸۱۰۹	۰.۱۸۰۴	۰.۱۸۱۸۹	۰.۱۸۱۶۱	۰.۱۸۰۸۶	۰.۱۷۸۴۴
FCM	۹	۰.۱۸۴۹	۰.۱۸۵۲۲	۰.۱۸۷۰۱	۰.۱۸۵۷۵	۰.۱۹۲۵۲	۰.۱۸۸۵۶
HIGCRL	۹	۰.۱۸۶۶۲	۰.۱۸۵۶۳	۰.۱۸۴۷۲	۰.۱۸۲۹۹	۰.۱۸۳۲	۰.۱۸۲۳۷
FCM	۸	۰.۱۸۷۰۲	۰.۱۸۶۴۲	۰.۱۹۴۶۵	۰.۱۹۱۴۵	۰.۱۹۹۸	۰.۱۹۳۳۲
HIGCRL	۸	۰.۱۸۹	۰.۱۸۶۷۹	۰.۱۸۶۲	۰.۱۸۵۲۹	۰.۱۸۶۶	۰.۱۸۵۱۸
FCM	۷	۰.۱۹۲۸۶	۰.۱۹۰۱۵	۰.۱۹۸۶۶	۰.۱۹۴۱	۰.۱۹۸۰۴	۰.۱۹۶۳۴
HIGCRL	۷	۰.۱۹۲۷۱	۰.۱۹۰۱	۰.۱۹۲۰۶	۰.۱۹۰۷۹	۰.۱۹۳۲۷	۰.۱۹۰۰۴
FCM	۶	۰.۱۹۶۲۳	۰.۱۹۲۴	۰.۱۹۹۴۵	۰.۱۹۴۵۶	۰.۱۹۵۹۵	۰.۱۹۵۸۵
HIGCRL	۶	۰.۱۹۶۰۸	۰.۱۹۲۲۱	۰.۱۹۵۱	۰.۱۹۳۱۳	۰.۱۹۵۴۵	۰.۱۹۲۴۵
FCM	۵	۰.۱۹۹۱۴	۰.۱۹۵۰۴	۰.۲۰۱۸۵	۰.۱۹۸۹۶	۰.۲۰۱۸۶	۰.۱۹۷۷۶
HIGCRL	۵	۰.۱۹۸۷	۰.۱۹۵۰۳	۰.۱۹۸۷۶	۰.۱۹۶۲۶	۰.۱۹۸۶۴	۰.۱۹۵۸۸
FCM	۴	۰.۲۰۰۸۷	۰.۱۹۹۷۵	۰.۲۰۳۴	۰.۲۰۰۱۴	۰.۲۰۴۴	۰.۲۰۰۲۸
HIGCRL	۴	۰.۲۰۴۳۷	۰.۲۰۰۵۷	۰.۲۰۲۶۲	۰.۱۹۸۹۳	۰.۲۰۲۸۲	۰.۱۹۹۱۸
FCM	۳	۰.۲۱۳۵۶	۰.۲۰۴۷۹	۰.۲۱۳۰۷	۰.۲۰۴۷	۰.۲۱۲۰۷	۰.۲۰۴۰۳
HIGCRL	۳	۰.۲۱۱۹۴	۰.۲۰۴۰۵	۰.۲۱۱۴۸	۰.۲۰۴۰۵	۰.۲۰۹۹	۰.۲۰۳۱۸
FCM	۲	۰.۲۲۵۲	۰.۲۱۶۰۹	۰.۲۲۴۳۱	۰.۲۱۵۸	۰.۲۲۳۷۱	۰.۲۱۵۵۶
HIGCRL	۲	۰.۲۲۶۳۷	۰.۲۱۶۳۸	۰.۲۲۴۸۷	۰.۲۱۵۷۴	۰.۲۲۴۰۶	۰.۲۱۵۰۲



جدول ۶.۳: میزان خطای مجموعه داده Balancescale

نام الگوریتم	C	خطای نمونه‌های آموزشی m = 2	خطای نمونه‌های آزمایشی m = 2	خطای نمونه‌های آموزشی m = 2.5	خطای نمونه‌های آزمایشی m = 2.5	خطای نمونه‌های آموزشی m = 2.9	خطای نمونه‌های آزمایشی m = 2.9
FCM	۱۰	۰.۲۵۳۵۴	۰.۲۴۷۳۳	۰.۲۳۸۱۸	۰.۲۳۳۸۵	۰.۲۳۴۷۱	۰.۲۳۴۷۱
HIGCRL	۱۰	۰.۲۴۴۱۴	۰.۲۴۳۲۵	۰.۲۴۴۶۶	۰.۲۵۳۹۵	۰.۲۳۵۶۱	۰.۲۳۵۶۱
FCM	۹	۰.۲۶۱۱۶	۰.۲۵۲۹۴	۰.۲۴۰۱	۰.۲۳۵۹۸	۰.۲۳۳۴۸	۰.۲۳۳۴۸
HIGCRL	۹	۰.۲۵۳۵۵	۰.۲۴۷۵۲	۰.۲۵۹۷۷	۰.۲۵۰۲۴	۰.۲۴۶۰۲	۰.۲۴۶۰۲
FCM	۸	۰.۲۸۱۳۴	۰.۲۷۶۵۸	۰.۲۴۳۳۱	۰.۲۳۷۲۴	۰.۲۳۸۹۲	۰.۲۳۸۹۲
HIGCRL	۸	۰.۲۷۳۳۷	۰.۲۶۴۰۱	۰.۲۷۴۶۳	۰.۲۶۳۰۵	۰.۲۴۹۹	۰.۲۴۹۹
FCM	۷	۰.۲۷۶۷۸	۰.۲۶۹۹۵	۰.۲۴۶۹۱	۰.۲۳۲۶۲	۰.۲۳۳۲	۰.۲۳۳۲
HIGCRL	۷	۰.۲۸۴۰۹	۰.۲۸۲۳۳	۰.۲۷۸۰۳	۰.۲۶۵۰۵	۰.۲۶۲۷۳	۰.۲۶۲۷۳
FCM	۶	۰.۲۷۹۲۹	۰.۲۷۰۵۴	۰.۲۵۰۲۴	۰.۲۳۶۷۱	۰.۲۳۶۵۳	۰.۲۳۶۵۳
HIGCRL	۶	۰.۲۸۷۹۹	۰.۲۸۰۴۹	۰.۲۸۳۶۱	۰.۲۶۶۰۷	۰.۲۵۹۷۳	۰.۲۵۹۷۳
FCM	۵	۰.۲۸۲۸۳	۰.۲۶۷۸۸	۰.۲۹۹۹۱	۰.۳۰۰۵۵	۰.۳۰۵۴۶	۰.۳۰۵۴۶
HIGCRL	۵	۰.۲۸۱۲۱	۰.۲۶۶۰۲	۰.۲۹۳۲	۰.۲۸۱۰۶	۰.۲۷۶۸۹	۰.۲۷۶۸۹
FCM	۴	۰.۲۸۰۱۵	۰.۲۷۴۶	۰.۲۷۳۳۸	۰.۳۲۵۶۶	۰.۳۲۷۲۲	۰.۳۲۷۲۲
HIGCRL	۴	۰.۳۱۴۵۸	۰.۲۹۵۶۳	۰.۳۱۴۱	۰.۳۰۳۴۳	۰.۳۰۲۴۸	۰.۳۰۲۴۸
FCM	۳	۰.۳۷۴۹۲	۰.۳۵۹۲۸	۰.۳۶۱۵۵	۰.۳۴۷۸۹	۰.۳۵۱۰۳	۰.۳۵۱۰۳
HIGCRL	۳	۰.۳۴۶۷۴	۰.۳۴۴۱۷	۰.۳۴۳۵۸	۰.۳۳۱۴۲	۰.۳۳۸۶۲	۰.۳۳۸۶۲
FCM	۲	۰.۳۸۸۳۹	۰.۳۸۵۶۴	۰.۳۸۲۰۱	۰.۳۷۲۶۳	۰.۳۶۴۲۹	۰.۳۶۴۲۹
HIGCRL	۲	۰.۳۶۵۷۹	۰.۳۴۷۲۹	۰.۳۴۵۵۶	۰.۳۴۳۱۶	۰.۳۴۲۷۴	۰.۳۴۲۷۴

جدول ۷.۳: میزان خطای مجموعه داده Pima

نام الگوریتم	C	خطای نمونه‌های آموزشی m = 2	خطای نمونه‌های آزمایشی m = 2	خطای نمونه‌های آموزشی m = 2.5	خطای نمونه‌های آزمایشی m = 2.5	خطای نمونه‌های آموزشی m = 2.9	خطای نمونه‌های آزمایشی m = 2.9
CSPA	۱۰	۰.۲۲۱۲۲	۰.۲۱۹۷۶	۰.۲۲۱۱۳	۰.۲۱۹۹	۰.۲۱۹۴۸	۰.۲۱۹۴۸
MCLA	۱۰	۰.۲۱۹۶	۰.۲۲۰۷۱	۰.۲۱۸۴۹	۰.۲۱۸۸۵	۰.۲۱۹۹۲	۰.۲۱۹۹۲
HGPA	۱۰	۰.۲۱۹۵۶	۰.۲۱۹۱۷	۰.۲۱۸۹۴	۰.۲۱۷۸۴	۰.۲۱۸۰۹	۰.۲۱۸۰۹
EM	۱۰	۰.۲۱۸۵۳	۰.۲۱۸۹۵	۰.۲۱۷۱۶	۰.۲۱۸۴۶	۰.۲۱۷۴۷	۰.۲۱۷۴۷
FCM	۱۰	۰.۲۲۱۳۸	۰.۲۱۹۷۵	۰.۲۲۱۲۶	۰.۲۱۸۸۷	۰.۲۲۲۱۸	۰.۲۲۲۱۸
CSPA	۹	۰.۲۲۱۹۳	۰.۲۱۹۶۱	۰.۲۲۱۱۱	۰.۲۲۰۲۴	۰.۲۲۰۳۳	۰.۲۲۰۳۳
MCLA	۹	۰.۲۲۰۴۲	۰.۲۱۸۷۲	۰.۲۲۰۷۳	۰.۲۱۸۷۸	۰.۲۱۹۳۳	۰.۲۱۹۳۳
HGPA	۹	۰.۲۲۰۷۳	۰.۲۱۸۸۸	۰.۲۱۹۶۳	۰.۲۱۷۴۳	۰.۲۱۷۲۴	۰.۲۱۷۲۴
EM	۹	۰.۲۱۹۵۳	۰.۲۱۸۲۲	۰.۲۲۰۳۶	۰.۲۱۹۶۳	۰.۲۱۷۹۸	۰.۲۱۷۹۸
FCM	۹	۰.۲۲۲۶۷	۰.۲۱۸۶۲	۰.۲۲۰۷۲	۰.۲۱۷۹۷	۰.۲۲۳۴۸	۰.۲۲۳۴۸
CSPA	۸	۰.۲۲۳۸۱	۰.۲۲۱۳۷	۰.۲۲۳۹۴	۰.۲۲۱۲۲	۰.۲۲۲۲۵	۰.۲۲۲۲۵
MCLA	۸	۰.۲۲۱۵۵	۰.۲۱۸۷۷	۰.۲۲۰۴۲	۰.۲۱۷۷	۰.۲۱۸۲۲	۰.۲۱۸۲۲
HGPA	۸	۰.۲۲۲۰۷	۰.۲۱۹۵۹	۰.۲۲۲۰۱	۰.۲۱۹۳۴	۰.۲۲۰۳۶	۰.۲۲۰۳۶
EM	۸	۰.۲۲۰۷۷	۰.۲۱۸۲۹	۰.۲۱۹۶۸	۰.۲۱۸۸۸	۰.۲۱۷۶۷	۰.۲۱۷۶۷
FCM	۸	۰.۲۲۱۶۸	۰.۲۱۸۴۱	۰.۲۲۲۴۹	۰.۲۲۱۵	۰.۲۲۱۶۵	۰.۲۲۱۶۵

جدول ۸.۳: ادامه میزان خطای مجموعه داده Pima

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۷	۰.۲۲۲۲۹	۰.۲۲۵۲۴	۰.۲۲۲۷۱	۰.۲۲۵۱۳	۰.۲۲۱۶۲	۰.۲۲۵۱۹
MCLA	۷	۰.۲۱۸۱۶	۰.۲۲۱۹۴	۰.۲۱۷۲۲	۰.۲۲۱۷۱	۰.۲۱۷۳	۰.۲۲۱۷۳
HGPA	۷	۰.۲۲۰۱۳	۰.۲۲۳۱۹	۰.۲۲	۰.۲۲۲۱۷	۰.۲۱۹۱۹	۰.۲۲۳۱۳
EM	۷	۰.۲۱۸۸	۰.۲۲۲۳۷	۰.۲۱۹۵	۰.۲۲۱۵۳	۰.۲۱۸۷۷	۰.۲۲۱۳۷
FCM	۷	۰.۲۱۸۱۵	۰.۲۲۳۶۸	۰.۲۲۲۰۴	۰.۲۲۵۳۸	۰.۲۲۱۹۸	۰.۲۲۲۴۶
CSPA	۶	۰.۲۲۰۷	۰.۲۲۵۹۵	۰.۲۲۱۱۱	۰.۲۲۵۷۹	۰.۲۲۱۳۵	۰.۲۲۵۹۸
MCLA	۶	۰.۲۱۷۸۶	۰.۲۲۲۵	۰.۲۱۷۷۱	۰.۲۲۲۰۳	۰.۲۱۸۴۲	۰.۲۲۲۵۶
HGPA	۶	۰.۲۲۱۰۵	۰.۲۲۳۵۹	۰.۲۲۱۴۱	۰.۲۲۲۷۶	۰.۲۲۲۰۸	۰.۲۲۳۷۴
EM	۶	۰.۲۱۹۶۸	۰.۲۲۳۱۶	۰.۲۲۰۰۷	۰.۲۲۳۵۹	۰.۲۱۷۴۳	۰.۲۲۲۵۵
FCM	۶	۰.۲۲	۰.۲۰۲۲۱۶	۰.۲۲۱۴۶	۰.۲۲۵۵۳	۰.۲۲	۰.۲۲۶۶۴
CSPA	۵	۰.۲۲۱۹۶	۰.۲۲۶۸	۰.۲۲۲۹۷	۰.۲۲۵۹۹	۰.۲۲۱۹۲	۰.۲۲۶۸۹
MCLA	۵	۰.۲۱۸۳۸	۰.۲۲۳۷۴	۰.۲۱۸۶۵	۰.۲۲۳۲	۰.۲۱۷۶۱	۰.۲۲۲۵
HGPA	۵	۰.۲۲۲۱۴	۰.۲۲۲۹۳	۰.۲۲۱۷۵	۰.۲۲۴۷۶	۰.۲۲۲۱	۰.۲۲۴۲۲
EM	۵	۰.۲۱۹۰۹	۰.۲۲۲۲	۰.۲۱۸۶۷	۰.۲۲۳۶۸	۰.۲۱۸۸۴	۰.۲۲۳۷
FCM	۵	۰.۲۱۹۷۵	۰.۲۲۲۷۳	۰.۲۲۲۷۸	۰.۲۲۵۵۱	۰.۲۲۲۷۶	۰.۲۲۲۴۲

جدول ۹.۳: ادامه میزان خطای مجموعه داده Pima

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۴	۰.۲۲۱۱۲	۰.۲۲۸۶۴	۰.۲۲۱۰۷	۰.۲۲۸۴۲	۰.۲۲۱۲۶	۰.۲۲۸۵۳
MCLA	۴	۰.۲۲۰۶۳	۰.۲۲۵۸۷	۰.۲۱۹۴	۰.۲۲۴۸۹	۰.۲۱۹۷۸	۰.۲۲۴۹
HGPA	۴	۰.۲۲۲	۰.۲۲۶۵۶	۰.۲۲۱۵۸	۰.۲۲۷۷۸	۰.۲۲۱۲۲	۰.۲۲۸۰۵
EM	۴	۰.۲۱۹۸	۰.۲۲۵۹۲	۰.۲۱۸۶۶	۰.۲۲۵۱۱	۰.۲۱۹۲۱	۰.۲۲۵۸۹
FCM	۴	۰.۲۲۰۶۲	۰.۲۲۷۴۹	۰.۲۲۰۵۶	۰.۲۲۸۴	۰.۲۲۰۵۵	۰.۲۲۸۶۶
CSPA	۳	۰.۲۲۲۱۹	۰.۲۲۸۹۴	۰.۲۲۱۴	۰.۲۲۹	۰.۲۲۲۴۶	۰.۲۲۹۰۱
MCLA	۳	۰.۲۲۰۸۱	۰.۲۲۷۲۵	۰.۲۲۰۴۲	۰.۲۲۷۲۹	۰.۲۲۰۶۷	۰.۲۲۸۰۳
HGPA	۳	۰.۲۲۱۷	۰.۲۲۷۴۶	۰.۲۲۲۰۹	۰.۲۲۷۶۴	۰.۲۲۱۸	۰.۲۲۸۲۵
EM	۳	۰.۲۲۰۳۱	۰.۲۲۷۴۶	۰.۲۲۰۱	۰.۲۲۷۵	۰.۲۲۰۴۷	۰.۲۲۷۵۷
FCM	۳	۰.۲۲۲۴۲	۰.۲۲۹۱۱	۰.۲۲۲۱۱	۰.۲۲۹۳۵	۰.۲۲۱۹۴	۰.۲۲۹۴۴
CSPA	۲	۰.۲۲۱۲۱	۰.۲۲۹۵۳	۰.۲۲۱۲۵	۰.۲۲۹۵۷	۰.۲۲۱۱۶	۰.۲۲۹۶۸
MCLA	۲	۰.۲۲۱۴	۰.۲۲۹۰۷	۰.۲۲۱۵۲	۰.۲۲۹۰۷	۰.۲۲۱۶۱	۰.۲۲۹۱
HGPA	۲	۰.۲۲۲۰۷	۰.۲۲۸۴۳	۰.۲۲۲۴۶	۰.۲۲۸۲۵	۰.۲۲۱۸۹	۰.۲۲۸۸۷
EM	۲	۰.۲۲۱۴۹	۰.۲۲۹۱۳	۰.۲۲۱۳۹	۰.۲۲۸۸۹	۰.۲۲۱۵۶	۰.۲۲۸۹۵
FCM	۲	۰.۲۲۱۱	۰.۲۲۹۵۲	۰.۲۲۱۱۳	۰.۲۲۹۵۷	۰.۲۲۱۱۴	۰.۲۲۹۶

جدول ۱۰.۳: میزان خطای مجموعه داده Servo

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۱۰	۱.۳۶۵۴۷	۲.۶۲۰۲۴	۱.۵۸۱۵	۲.۱۱۰۹	۱.۵۸۵۶	۲.۱۲۴۸
MCLA	۱۰	۱.۴۴۰۴۳	۲.۶۷۱۰۲	۱.۶۶۱۴۷	۲.۲۰۰۰۵	۱.۶۲۹۶۸	۲.۱۳۴۷۹
HGPA	۱۰	۱.۳۵۸۲۲	۲.۵۸۹۳۷	۱.۴۸۱۶۶	۲.۰۰۲۴	۱.۵۴۳۱۳	۲.۳۲۹۷
EM	۱۰	۱.۳۰۷۰۹	۴.۶۸۷۷۴	۱.۵۴۹۰۶	۵.۲۴۹۴۱	۱.۳۸۵۱۳	۹.۶۸۴۸۴
FCM	۱۰	۱.۴۰۳۵۸	۲.۶۷۵۴۵	۱.۸۷۲۲۸	۲.۲۹۶۱۱	۱.۸۳۳۲۱	۹.۷۶۶۱۴
CSPA	۹	۱.۳۹۲۴۴	۲.۶۳۴۹	۱.۵۹۸۵۱	۲.۱۵۹۴۶	۱.۶۳۸۹۷	۲.۲۰۵۹۵
MCLA	۹	۱.۴۱۷۱۹	۲.۶۲۵۳۶	۱.۶۵۴۶۲	۲.۱۶۰۵۱	۱.۶۷۷۴۷	۲.۱۷۹۹۲
HGPA	۹	۱.۳۹۲۵	۲.۵۹۹۹۸	۱.۶۱۹۸۱	۲.۱۲۵۶۸	۱.۵۷۲۸۴	۲.۱۲۴۹۸
EM	۹	۱.۲۴۰۲۷	۳.۴۳۱۳۳	۱.۵۷۴۷۷	۶.۴۸۱۲۶	۱.۵۸۴۶۵	۳.۴۴۰۴۸
FCM	۹	۱.۳۹۰۵۵	۲.۷۷۴۵۳	۱.۸۹۶۲۵	۲.۳۸۰۴۲	۱.۸۶۸۷۸	۵.۱۸۲۸۷
CSPA	۸	۱.۴۲۶۸۶	۲.۶۷۷۲۲	۱.۶۹۴۵۱	۲.۲۶۳۰۲	۱.۶۷۹۱۸	۲.۲۴۴۷۱
MCLA	۸	۱.۴۲۱۱۷	۲.۶۶۵۹	۱.۷۵۰۴۵	۲.۲۲۹۰۸	۱.۷۳۰۳۳	۲.۲۴۶۰۵
HGPA	۸	۱.۳۸۹۴۵	۲.۶۱۷۸۳	۱.۶۶۷۵۷	۲.۱۹۸۲۲	۱.۶۵۳۰۴	۲.۱۲۳۰۱
EM	۸	۱.۳۱۰۵۶	۴.۱۶۳۸۲	۱.۶۱۲۶۱	۴.۴۴۶۹۷	۱.۶۳۵۸۵	۳.۷۶۷۵۷
FCM	۸	۱.۴۶۸۶۱	۲.۶۹۵۱۶	۱.۸۸۶۲۶	۲.۳۸۷۴۶	۱.۸۹۵	۳.۳۷۲۳۴

جدول ۱۱.۳: ادامه میزان خطای مجموعه داده Servo

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۷	۱.۴۴۷۶	۲.۷۰۶۹۸	۱.۷۱۳۴	۲.۲۷۶۴۷	۱.۷۳۵۰۷	۲.۲۴۱۷۴
MCLA	۷	۱.۴۶۵	۲.۶۷۳۲	۱.۷۴۸۸۸	۲.۲۰۳۷۸	۱.۷۲۶۳۵	۲.۱۸۴۸۱
HGPA	۷	۱.۴۵۵۰۹	۲.۶۷۶۱۲	۱.۷۲۹۱۸	۲.۲۰۵۵۶	۱.۶۹۱۳۴	۲.۱۷۶۹۹
EM	۷	۱.۴۵۳۲۴	۳.۱۸۳۹۷	۱.۷۵۵۳۴	۳.۰۹۱۳۳	۱.۶۹۳۴۵	۳.۸۵۰۷
FCM	۷	۱.۵۲۲۱	۲.۷۲۱۷۴	۱.۹۰۵۷۱	۲.۳۵۱۹۵	۱.۹۱۴۱۲	۳.۱۴۳۱۲
CSPA	۶	۱.۴۶۰۰۴	۲.۶۸۴۱۴	۱.۷۸۱۹۷	۲.۲۴۲۹۵	۱.۷۵۰۲۵	۲.۲۳۷۴۷
MCLA	۶	۱.۴۸۶۳۳	۲.۷۱۶۶۹	۱.۸۱۶۱۸	۲.۲۴۵۸۶	۱.۸۰۳۹۴	۲.۲۳۳۱۷
HGPA	۶	۱.۴۳۵۲۳	۲.۶۶۲۸	۱.۷۴۶۶۸	۲.۱۹۳۵۶	۱.۷۰۸۱۶	۲.۱۵۶۸۳
EM	۶	۱.۴۹۵۴	۳.۳۴۷۸۹	۱.۸۱۱۳۷	۲.۶۰۵۲۸	۱.۷۵۵۶۴	۳.۴۵۸۴۴
FCM	۶	۱.۵۱۵۴۲	۲.۷۰۷۸۶	۱.۸۷۷۴۲	۲.۲۸۵۶۸	۱.۹۳۳۴۴	۲.۵۹۹۶۸
CSPA	۵	۱.۵۰۶۱۱	۲.۷۲۹۱۲	۱.۷۹۱۵۵	۲.۲۵۱۶	۱.۸۰۰۰۵	۲.۲۳۰۲۸
MCLA	۵	۱.۴۹۶۵	۲.۷۵۳۱۲	۱.۸۲۶۷۷	۲.۲۲۴۷۳	۱.۸۲۵۵۷	۲.۲۲۵۳۶
HGPA	۵	۱.۴۵۰۸۸	۲.۶۳۹۰۶	۱.۷۸۶۶۳	۲.۲۲۷۹۴	۱.۸۰۲۲۸	۲.۲۳۶۰۷
EM	۵	۱.۵۱۶۶۹	۳.۲۴۲۶	۱.۸۲۶۹۵	۲.۶۷۸۰۶	۱.۸۱۸۶۲	۲.۷۲۲۰۸
FCM	۵	۱.۵۱۷۲۸	۲.۷۳۶۸۶	۱.۹۰۷۷۵	۲.۳۱۹۲۶	۱.۹۲۲۲۵	۲.۳۷۱۶

جدول ۱۲.۳: ادامه میزان خطای مجموعه داده Servo

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۴	۱.۵۳۹۰۴	۲.۷۸۱۵	۱.۸۶۵۷۴	۲.۳۱۱۰۱	۱.۸۷۱۳۷	۲.۲۶۵۰۲
MCLA	۴	۱.۵۴۴۱	۲.۸۱۱۷۴	۱.۸۷۲۲۶	۲.۳۰۳۳۴	۱.۸۶۳۶۲	۲.۳۱۵۹۲
HGPA	۴	۱.۵۴۸	۲.۸۰۰۱۵	۱.۸۶۵۳۱	۲.۳۰۰۳۳	۱.۸۶۰۶۸	۲.۲۷۳۷
EM	۴	۱.۵۵۵۸۱	۳.۰۱۵۲۵	۱.۸۶۵۷۵	۲.۶۰۲۱	۱.۸۸۷۳۵	۲.۶۵۰۰۵
FCM	۴	۱.۵۵۷۱۱	۲.۷۹۰۲۴	۱.۹۰۴۹۴	۲.۳۳۹۸۷	۱.۹۱۳۱۳	۲.۳۸۸۲۸
CSPA	۳	۱.۵۸۲۸۳	۲.۸۵۶۸۱	۱.۸۹۰۶	۲.۳۲۴۹۳	۱.۹۰۹۱۷	۲.۳۲۶۷۴
MCLA	۳	۱.۵۹۰۰۳	۲.۸۵۸۴۸	۱.۹۱۲۵۹	۲.۳۴۱۵۹	۱.۹۳۶۵۶	۲.۳۵۹۱
HGPA	۳	۱.۶۰۸۵۵	۲.۸۶۴۰۸	۱.۹۰۴۷۸	۲.۳۲۸۶۸	۱.۹۱۶۷۸	۲.۳۴۲۶۵
EM	۳	۱.۶۶۸۷۵	۳.۰۸۹۱	۱.۹۶۲۸۳	۲.۶۰۲۴	۲.۰۱۱۴	۲.۶۹۲۵۵
FCM	۳	۱.۶۱۱۳۶	۲.۹۳۴۲۵	۱.۹۷۰۰۴	۲.۳۲۴۰۹	۱.۹۴۶۱۵	۲.۳۷۱۰۳
CSPA	۲	۱.۷۶۶۶۵	۳.۱۰۵۴۷	۲.۰۶۰۶۹	۲.۵۲۳۰۷	۲.۰۹۰۶۶	۲.۵۶۰۹۳
MCLA	۲	۱.۷۱۱۴	۲.۹۸۳۹۳	۲.۰۸۶۵۶	۲.۵۱۱۸۶	۲.۰۹۲۶	۲.۵۱۹۱۹
HGPA	۲	۱.۷۵۵۷۶	۳.۱۰۶۶۸	۲.۱۷۹۴۶	۲.۶۲۳۸۸	۲.۰۹۰۴۲	۲.۵۳۵۹۹
EM	۲	۱.۷۶۹۲۴	۳.۱۶۳۸۴	۲.۰۹۴۷	۲.۶۹۶۹۴	۲.۱۱۹۶۷	۲.۷۲۹۰۸
FCM	۲	۱.۵۸۹۶۴	۲.۹۰۴۵۸	۲.۰۱۷۸۴	۲.۴۵۵۸۹	۲.۰۵۷۸۹	۲.۶۲۲۵۳

جدول ۱۳.۳: میزان خطای مجموعه داده Housing

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۱۰	۶۶.۸۲۶۶۴	۵۶.۱۸۵۳۴	۶۶.۲۲۲۵۱	۵۵.۶۸۲۱	۶۶.۵۲۰۱	۵۵.۳۴۱۷۹
MCLA	۱۰	۶۵.۲۳۵۹۴	۵۲.۵۸۰۴۶	۶۵.۱۶۴۹۱	۵۲.۹۱۹۶۴	۶۵.۹۹۵۴۲	۵۲.۵۰۸۲۹
HGPA	۱۰	۶۵.۴۶۰۳۳	۵۳.۹۳۰۲۸	۶۵.۴۸۶۹۶	۵۴.۰۸۵۵۱	۶۵.۸۲۹۳۳	۵۴.۶۱۴۷۱
EM	۱۰	۶۶.۸۵۰۵۳	۵۵.۱۳۰۰۳	۶۶.۷۶۶۴۳	۵۶.۳۴۳۴۶	۶۶.۲۷۳۸۵	۵۵.۴۷۳۵۸
FCM	۱۰	۶۷.۶۶۰۴۴	۵۴.۳۹۱۲۲	۶۸.۶۹۱۱۲	۵۴.۰۴۰۱	۶۹.۱۷۲۴۵	۵۴.۲۲۶۳۴
CSPA	۹	۶۷.۸۸۶۱۸	۵۸.۵۴۴۹۸	۶۸.۴۵۱۶	۵۸.۷۸۶۱۵	۶۸.۳۷۳۵۷	۵۹.۹۲۹۶۳
MCLA	۹	۶۵.۹۱۵۸۹	۵۳.۴۱۸۷۸	۶۶.۵۱۹۰۲	۵۳.۸۷۵۲۱	۶۵.۹۹۵۴۲	۵۳.۱۲۴۶۴
HGPA	۹	۶۶.۹۸۹۳۹	۵۴.۷۴۶۹۴	۶۷.۴۳۵۸	۵۴.۹۴۹۸۹	۶۶.۹۵۶۰۳	۵۵.۶۲۵۴۴
EM	۹	۶۷.۲۲۳۱۴	۵۵.۹۷۱۱۹	۶۷.۲۸۹۵۶	۵۶.۲۰۹۲۶	۶۷.۳۴۹۵۳	۵۵.۶۹۹۸۶
FCM	۹	۶۸.۱۸۵۶۵	۵۴.۳۳۷۵۲	۶۹.۰۱۸۳۸	۵۴.۶۰۲۵۳	۶۹.۵۵۱۰۷	۵۴.۴۹۸۴۳
CSPA	۸	۶۹.۳۸۱۵۶	۵۵.۸۸۵۴	۷۰.۳۵۹۰۴	۵۶.۸۳۰۰۱	۷۰.۵۷۲۱۹	۵۶.۷۲۲۱۲
MCLA	۸	۶۶.۷۲۳۹۳	۵۳.۳۸۶۲۲	۶۷.۲۶۶۵۵	۵۳.۸۶۰۸۳	۶۷.۱۰۹۵	۵۳.۶۵۷۵۶
HGPA	۸	۶۶.۷۸۱۰۷	۵۳.۷۸۴۶۴	۶۷.۳۱۲۹۸	۵۵.۷۳۳۲۱	۶۷.۲۹۸۷۳	۵۵.۴۸۸۲۹
EM	۸	۶۸.۰۱۴۴۱	۵۶.۴۶۹۸۸	۶۸.۰۲۷۷۷	۵۵.۹۸۰۷۶	۶۸.۲۸۵۱۳	۵۶.۷۴۰۷۶
FCM	۸	۶۸.۲۲۸۷۵	۵۴.۱۳۰۷۲	۶۹.۲۸۴۵۸	۵۴.۶۵۹۷۲	۶۹.۹۱۴۳۶	۵۴.۹۰۱۷۵

جدول ۱۴.۳: ادامه میزان خطای مجموعه داده Housing

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۷	۶۸.۵۷۷۵۴	۵۴.۴۴۶۸۳	۶۸.۸۸۹۳۹	۵۴.۹۳۴۴۹	۶۸.۸۳۳۱۶	۵۴.۹۱۴۳۶
MCLA	۷	۶۷.۹۴۴۲۲	۵۴.۳۲۹۵۳	۶۷.۹۴۵۷۸	۵۴.۲۱۲۶۷	۶۸.۵۹۲۸۷	۵۵.۰۱۵۳۱
HGPA	۷	۶۸.۰۴۱۷۵	۵۵.۳۸۴۷۶	۶۸.۲۷۵۵۱	۵۵.۹۴۰۸۷	۶۸.۶۷۱۳۲	۵۵.۵۱۷۲۱
EM	۷	۶۸.۷۴۶۹۷	۵۶.۴۷۱۳۵	۶۸.۶۰۵۴۸	۵۶.۶۳۹۱۸	۶۹.۶۹۹۷۳	۵۷.۸۵۱۶۵
FCM	۷	۶۸.۴۱۹۵	۵۳.۶۲۹۴۵	۶۹.۴۸۲۴۲	۵۴.۴۴۱۷۵	۷۰.۱۲۶۱۵	۵۵.۰۹۰۳۴
CSPA	۶	۶۷.۸۲۹۱۱	۵۴.۱۹۴۸۸	۶۸.۳۳۴۷	۵۴.۸۵۱۳۴	۶۸.۱۳۹	۵۵.۱۵۱۵۶
MCLA	۶	۶۸.۲۷۹۸۵	۵۳.۶۸۹۵۷	۶۸.۵۳۳۷۸	۵۴.۳۷۰۴۶	۶۸.۹۵۱۷۴	۵۵.۰۲۲۵۱
HGPA	۶	۶۸.۲۳۷۵	۵۴.۳۵۹۳۵	۶۸.۳۹۳۳۲	۵۵.۰۹۷۰۵	۶۸.۷۵۴۱۵	۵۴.۶۸۲۰۹
EM	۶	۶۹.۶۵۹۷۱	۵۷.۹۳۷۰۹	۶۹.۵۴۸۲۱	۵۷.۰۴۶۰۴	۶۹.۶۲۵۰۳	۵۶.۷۷۵۹
FCM	۶	۶۸.۵۱۴۲۵	۵۳.۸۲۵۷۹	۶۹.۶۵۲۶۱	۵۳.۹۵۱۶۷	۷۰.۰۵۷۴۱	۵۴.۲۶۵۱۶
CSPA	۵	۶۹.۹۲۷۲۸	۵۶.۴۲۲۴۱	۷۰.۵۵۴۹	۵۶.۵۷۹۳	۷۱.۰۰۳۸۴	۵۷.۴۳۵۷۹
MCLA	۵	۶۹.۴۳۵۰۸	۵۵.۷۳۳۴	۶۹.۴۶۲۳۵	۵۶.۱۸۶۶۶	۶۹.۹۲۳۳۶	۵۶.۹۷۶۶۷
HGPA	۵	۶۸.۹۲۲۱۷	۵۵.۷۵۵۱۲	۶۹.۱۱۴۶۸	۵۵.۹۹۲۲۴	۶۹.۹۸۱۳	۵۶.۱۱۱۳۱
EM	۵	۷۰.۴۷۵۹۶	۵۷.۱۲۴۷	۷۰.۳۷۵۷۹	۵۷.۷۱۵۴۴	۷۱.۳۸۴۶۲	۵۸.۲۵۳۸۳
FCM	۵	۶۸.۲۸۱۲۴	۵۴.۱۷۵۴۸	۶۸.۸۳۵۱۹	۵۴.۶۶۰۴۷	۶۸.۸۵۳۱۷	۵۵.۱۸۱۳۹

جدول ۱۵.۳: ادامه میزان خطای مجموعه داده Housing

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۴	۷۱.۰۳۹۱۴	۵۸.۹۳۹۵۹	۷۱.۴۵۶۱۲	۵۹.۷۷۷۵۱	۷۱.۶۱۴۳۴	۶۰.۰۵۵۲۹
MCLA	۴	۷۱.۰۳۱۹۲	۵۷.۷۶۹۲۶	۷۱.۶۰۴۹۴	۵۸.۴۹۳۰۱	۷۱.۸۳۴۲۷	۵۹.۴۲۴۵۲
HGPA	۴	۷۰.۹۶۵۶۲	۵۷.۲۸۲۸۸	۷۱.۳۹۶۷۳	۵۸.۰۴۵۹۱	۷۱.۹۰۰۱۱	۵۸.۹۲۰۰۱
EM	۴	۷۲.۰۸۴۴۳	۵۶.۹۰۳۳۹	۷۱.۹۲۶۳۸	۵۸.۰۴۹۹۴	۷۲.۷۸۳۶۹	۵۸.۴۹۳۵۹
FCM	۴	۷۱.۴۸۴۳۹	۵۴.۸۶۷۲۸	۷۲.۳۳۷۱۱	۵۶.۳۶۳۷۵	۷۳.۶۳۸۵۲	۵۸.۷۱۴۶۶
CSPA	۳	۷۴.۰۶۲۴۴	۵۸.۳۵۸۲۸	۷۴.۰۵۳۱۷	۵۸.۶۶۸۲۷	۷۴.۲۳۸۷۲	۵۸.۷۵۸۳۸
MCLA	۳	۷۲.۴۶۴۹۸	۵۸.۰۲۹۶۱	۷۲.۷۴۴۶	۵۸.۷۱۲۴۱	۷۳.۳۶۷۹۵	۵۸.۸۶۰۱۱
HGPA	۳	۷۲.۱۷۴۸۴	۵۷.۶۸۶۴۲	۷۲.۸۹۲۱	۵۸.۲۸۹۲۹	۷۲.۷۶۵۰۹	۵۸.۵۸۵۱۳
EM	۳	۷۳.۱۵۵۰۶	۵۶.۸۴۶۳۴	۷۴.۶۶۶۷	۵۸.۴۴۵۵۱	۷۴.۲۸۳۴۹	۵۷.۸۷۱
FCM	۳	۷۴.۲۶۲۰۵	۵۷.۴۵۷۷۴	۷۵.۶۱۵۰۱	۵۹.۲۲۰۰۷	۷۶.۳۷۸۷	۶۰.۰۸۵۸۵
CSPA	۲	۷۳.۵۶۶۴۶	۵۶.۱۵۳۳۳	۷۴.۰۹۰۸۸	۵۶.۸۲۱۵۱	۷۴.۳۹۳۸۴	۵۷.۲۲۴۹۹
MCLA	۲	۷۳.۲۸۰۱۹	۵۶.۱۷۱	۷۴.۱۲۵۰۸	۵۶.۸۳۲۵۱	۷۴.۱۸۱۱	۵۷.۰۸۷۶۴
HGPA	۲	۷۳.۵۴۵۵۴	۵۶.۱۳۷۶۶	۷۴.۱۹۰۰۷	۵۶.۷۷۳۹۵	۷۴.۴۳۸۱۱	۵۷.۱۷۱۲۴
EM	۲	۷۶.۴۰۰۶۵	۵۸.۶۶۹۱۷	۷۸.۱۳۷۵	۵۹.۹۷۴۶۹	۷۷.۳۰۷۸۷	۵۹.۵۱۴۹۶
FCM	۲	۷۴.۳۴۴۸۶	۵۷.۵۹۰۳۴	۷۵.۱۷۴۴۳	۵۸.۲۹۷۰۸	۷۵.۷۸۷۵۵	۵۸.۷۸۲۴۴

جدول ۱۶.۳: میزان خطای مجموعه داده Biodegration

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۱۰	۰.۱۸۴۸۳	۰.۱۸۳۹۱	۰.۱۸۳۴۶	۰.۱۸۴۵۴	۰.۱۸۲۹۳	۰.۱۸۳۵۹
MCLA	۱۰	۰.۱۷۹۴۲	۰.۱۷۸۵۵	۰.۱۷۶۷۱	۰.۱۷۷۴۱	۰.۱۷۶۲۳	۰.۱۷۷۴۲
HGPA	۱۰	۰.۱۷۹۴۷	۰.۱۷۹۰۵	۰.۱۷۹۹۵	۰.۱۷۹۹۷	۰.۱۷۸۰۸	۰.۱۷۷۳۸
EM	۱۰	۰.۱۸۶۳۶	۰.۱۸۷۱۴	۰.۱۸۵۴۲	۰.۱۸۴۸	۰.۱۸۴۹۷	۰.۱۸۴۳۹
FCM	۱۰	۰.۱۸۱۸۱	۰.۱۸۰۶۴	۰.۱۸۲۶۶	۰.۱۸۵۱	۰.۹۰۳۷۴	۰.۸۶۷۷۴
CSPA	۹	۰.۱۸۸۶۹	۰.۱۸۷۰۶	۰.۱۸۳۲۹	۰.۱۸۴۸۶	۰.۱۸۳۹۴	۰.۱۸۵۸۲
MCLA	۹	۰.۱۸۰۵۳	۰.۱۷۹۹۴	۰.۱۷۸۷۴	۰.۱۸۰۴۲	۰.۱۷۸۹۲	۰.۱۸۱۲۳
HGPA	۹	۰.۱۸۴۲۵	۰.۱۸۴۵۲	۰.۱۸۱۱۶	۰.۱۸۱۳۶	۰.۱۸۲۸۸	۰.۱۸۳۲۲
EM	۱۰	۰.۱۸۴۰۷	۰.۱۸۴۴۷	۰.۱۸۶۱۹	۰.۱۸۵۹۹	۰.۱۸۶۲۹	۰.۱۸۵۹۸
FCM	۱۰	۰.۱۸۴۹	۰.۱۸۵۲۲	۰.۱۸۵۷۵	۰.۱۸۷۰۱	۰.۱۸۸۵۶	۰.۱۹۲۵۲
CSPA	۸	۰.۱۹۰۱۱	۰.۱۸۹۶۶	۰.۱۸۷۶۴	۰.۱۹۰۳۵	۰.۱۸۷۵۱	۰.۱۹
MCLA	۸	۰.۱۸۷۶۹	۰.۱۸۶۱۴	۰.۱۸۵۰۴	۰.۱۸۶۸۵	۰.۱۸۲۷۱	۰.۱۸۳۳۵
HGPA	۸	۰.۱۸۸۱۱	۰.۱۸۸۶۲	۰.۱۸۵۷۷	۰.۱۸۵۲۶	۰.۱۸۳۶۱	۰.۱۸۵۸۱
EM	۸	۰.۱۹۳۵	۰.۱۹۱۷	۰.۱۸۸۰۹	۰.۱۹۰۳	۰.۱۸۹۵۸	۰.۱۹۰۲۷
FCM	۸	۰.۱۸۷۰۲	۰.۱۸۶۴۲	۰.۱۹۱۴۵	۰.۱۹۴۶۵	۰.۱۹۳۳۲	۰.۱۹۹۸

جدول ۱۷.۳: ادامه میزان خطای مجموعه داده Biodegration

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۷	۰.۱۹۱۶۵	۰.۱۹۰۹۸	۰.۱۸۷۹۵	۰.۱۸۸۷۲	۰.۱۸۶۶۸	۰.۱۸۷۵۱
MCLA	۷	۰.۱۹۲۵۶	۰.۱۹۰۵۷	۰.۱۸۷۸۹	۰.۱۹۰۳	۰.۱۸۶۲۴	۰.۱۸۹۰۹
HGPA	۷	۰.۱۸۹۷۷	۰.۱۸۹۴۵	۰.۱۸۷۷	۰.۱۸۸۰۳	۰.۱۸۷۶۳	۰.۱۸۹۲۲
EM	۷	۰.۱۹۶۱۶	۰.۱۹۳۱۴	۰.۱۹۲۲۴	۰.۱۹۵۰۷	۰.۱۸۸۳۹	۰.۱۹۱۲۵
FCM	۷	۰.۱۹۲۸۶	۰.۱۹۰۱۵	۰.۱۹۴۱	۰.۱۹۸۶۶	۰.۱۹۶۳۴	۰.۱۹۸۰۴
CSPA	۶	۰.۱۹۸۱۱	۰.۱۹۴۸۸	۰.۱۹۳۰۸	۰.۱۹۶۲۴	۰.۱۹۴۵	۰.۱۹۸۵۱
MCLA	۶	۰.۱۹۳۷۶	۰.۱۹۱۴۱	۰.۱۹۰۴۱	۰.۱۹۲۷۶	۰.۱۹۱۱۶	۰.۱۹۴۱۹
HGPA	۶	۰.۱۹۱۴	۰.۱۹۱۱۱	۰.۱۹۰۹۷	۰.۱۹۲۳۱	۰.۱۹۰۱۶	۰.۱۹۱۲
EM	۶	۰.۲۰۱۴۵	۰.۱۹۷۹	۰.۱۹۵۹۸	۰.۱۹۸۹۶	۰.۱۹۲۳۹	۰.۱۹۶۰۶
FCM	۶	۰.۱۹۶۲۳	۰.۱۹۲۴	۰.۱۹۴۵۶	۰.۱۹۹۴۵	۰.۱۹۵۸۵	۰.۱۹۵۹۵
CSPA	۵	۰.۱۹۶۹۴	۰.۱۹۴۷۲	۰.۱۹۳۹	۰.۱۹۷۱۹	۰.۱۹۴۸۲	۰.۱۹۶۸۱
MCLA	۵	۰.۱۹۷۲۸	۰.۱۹۴۸۱	۰.۱۹۳۵۵	۰.۱۹۶۵	۰.۱۹۴۴۲	۰.۱۹۵۹۵
HGPA	۵	۰.۱۹۹۰۶	۰.۱۹۶۶۳	۰.۱۹۵۶۸	۰.۱۹۸۳۲	۰.۱۹۴۳۷	۰.۱۹۷۱۸
EM	۵	۰.۲۰۳۸۶	۰.۱۹۸۲	۰.۱۹۷۷۶	۰.۲۰۲۹۱	۰.۱۹۶۷	۰.۲۰۱۵۳
FCM	۵	۰.۱۹۹۱۴	۰.۱۹۵۰۴	۰.۱۹۸۹۶	۰.۲۰۱۸۵	۰.۱۹۷۷۶	۰.۲۰۱۸۶

جدول ۱۸.۳: ادامه میزان خطای مجموعه داده Biodegration

نام الگوریتم	C	خطای نمونه‌های آموزشی m = 2	خطای نمونه‌های آزمایشی m = 2	خطای نمونه‌های آموزشی m = 2.5	خطای نمونه‌های آزمایشی m = 2.5	خطای نمونه‌های آموزشی m = 2.9	خطای نمونه‌های آزمایشی m = 2.9
CSPA	۴	۰.۲۰۴۹۲	۰.۱۹۹۹۷	۰.۲۰۰۷۱	۰.۱۹۶۸۹	۰.۲۰۴۰۷	۰.۱۹۸۵۶
MCLA	۴	۰.۱۹۹۵۳	۰.۱۹۷۹۵	۰.۲۰۰۸۳	۰.۱۹۸۲۹	۰.۱۹۸۹	۰.۱۹۷
HGPA	۴	۰.۲۰۰۰۱	۰.۱۹۶۱۶	۰.۲۰۱۰۴	۰.۱۹۶۵۲	۰.۲۰۰۰۵	۰.۱۹۵۷۸
EM	۴	۰.۲۰۶۷۴	۰.۲۰۰۷۱	۰.۲۰۶۳۶	۰.۲۰۰۶۱	۰.۲۰۳۱۸	۰.۱۹۷۴۴
FCM	۴	۰.۲۰۰۸۷	۰.۱۹۹۷۵	۰.۲۰۳۴	۰.۲۰۰۱۴	۰.۲۰۴۴	۰.۲۰۰۴۸
CSPA	۳	۰.۲۱۳۳۵	۰.۲۰۵۱۶	۰.۲۱۱۹۵	۰.۲۰۴۱۸	۰.۲۱۲۲۳	۰.۲۰۴۴۴
MCLA	۳	۰.۲۱۱۳۶	۰.۲۰۳۶۱	۰.۲۰۸۹۶	۰.۲۰۱۹	۰.۲۱۱۶۱	۰.۲۰۳۳۶
HGPA	۳	۰.۲۰۹۰۲	۰.۲۰۱۸۵	۰.۲۰۹۶۵	۰.۲۰۲۲۹	۰.۲۰۸۲۸	۰.۲۰۱۰۹
EM	۳	۰.۲۱۱۴۷	۰.۲۰۴۰۸	۰.۲۱۱۳۱	۰.۲۰۴۵۵	۰.۲۱۲۵۵	۰.۲۰۴۶۳
FCM	۳	۰.۲۱۳۵۶	۰.۲۰۴۷۹	۰.۲۱۳۰۷	۰.۲۰۴۷	۰.۲۱۲۰۷	۰.۲۰۴۰۳
CSPA	۲	۰.۲۱۳۷۹	۰.۲۰۵۳۳	۰.۲۱۵۰۱	۰.۲۰۶۵۹	۰.۲۱۴۴۳	۰.۲۰۶۲۶
MCLA	۲	۰.۲۱۸۵۹	۰.۲۱۰۱۲	۰.۲۱۹۹	۰.۲۱۱۷۳	۰.۲۱۸۰۳	۰.۲۰۹۲۳
HGPA	۲	۰.۲۱۹۱۷	۰.۲۱۱۷۴	۰.۲۱۸۴۸	۰.۲۱۰۴۲	۰.۲۱۹۰۸	۰.۲۱۰۹۸
EM	۲	۰.۲۱۷۱۵	۰.۲۰۸۸۶	۰.۲۱۸۰۲	۰.۲۰۸۸۶	۰.۲۱۸۴۸	۰.۲۰۹۴۵
FCM	۲	۰.۲۲۵۲	۰.۲۱۶۰۹	۰.۲۲۴۳۱	۰.۲۱۵۸	۰.۲۲۳۷۱	۰.۲۱۵۵۶

جدول ۱۹.۳: میزان خطای مجموعه داده Balancescale

نام الگوریتم	C	خطای نمونه‌های آموزشی m = 2	خطای نمونه‌های آزمایشی m = 2	خطای نمونه‌های آموزشی m = 2.5	خطای نمونه‌های آزمایشی m = 2.5	خطای نمونه‌های آموزشی m = 2.9	خطای نمونه‌های آزمایشی m = 2.9
CSPA	۱۰	۰.۲۴۹۱۹	۰.۲۳۹۷۵	۰.۲۴۱۴۸	۰.۲۳۴۱۲	۰.۲۴۱۷۵	۰.۲۳۲۹۵
MCLA	۱۰	۰.۲۴۷۴۹	۰.۲۳۹۲۸	۰.۲۳۹۱۷	۰.۲۳۳۲۳	۰.۲۳۸۰۴	۰.۲۳۱۴۱
HGPA	۱۰	۰.۲۵۴۴۲	۰.۲۴۹۹۸	۰.۲۵۱۳۶	۰.۲۴۶۲۶	۰.۲۳۸۰۶	۰.۲۳۴۱۶
EM	۱۰	۰.۲۳۹۶۳	۰.۲۴۱۸۲	۰.۲۳۴۵۴	۰.۲۳۰۱۶	۰.۲۳۶۹۵	۰.۲۲۸۰۲
FCM	۱۰	۰.۲۵۳۵۴	۰.۲۴۷۳۳	۰.۲۳۸۱۸	۰.۲۳۳۸۵	۰.۲۳۴۱۵	۰.۲۳۴۷۱
CSPA	۹	۰.۲۵۰۹۷	۰.۲۴۲۷۶	۰.۲۴۶۸۴	۰.۲۳۶۶۲	۰.۲۴۴۱۳	۰.۲۳۴۳۶
MCLA	۹	۰.۲۵۰۹۶	۰.۲۴۰۴۹	۰.۲۴۷۸	۰.۲۳۶۹۴	۰.۲۴۹۸۵	۰.۲۳۶۵۷
HGPA	۹	۰.۲۵۹۲۲	۰.۲۵۳۰۸	۰.۲۵۳۷	۰.۲۴۶۲۱	۰.۲۵۱۶۹	۰.۲۴۱۳۸
EM	۹	۰.۲۴۲۲۷	۰.۲۳۵۱۶	۰.۲۴۰۹۴	۰.۲۲۹۹	۰.۲۴۳۱	۰.۲۳۱۳۱
FCM	۹	۰.۲۶۱۱۶	۰.۲۵۲۹۴	۰.۲۴۰۱	۰.۲۳۵۹۸	۰.۲۳۸۸۷	۰.۲۳۳۴۸
CSPA	۸	۰.۲۶۳۵۱	۰.۲۵۱۵۹	۰.۲۶۰۱۲	۰.۲۵۰۱	۰.۲۵۷۷۱	۰.۲۴۴۲
MCLA	۸	۰.۲۶۰۴۶	۰.۲۵۰۴۸	۰.۲۵۵۰۶	۰.۲۴۲۷۵	۰.۲۵۵۵۱	۰.۲۴۳۶۳
HGPA	۸	۰.۲۶۱۳۵	۰.۲۵۴۴	۰.۲۶۱۳۶	۰.۲۴۹۵۴	۰.۲۵۵۴۷	۰.۲۴۶۹۹
EM	۸	۰.۲۴۳۶	۰.۲۳۵۳۴	۰.۲۴۴۰۱	۰.۲۳۶۱۲	۰.۲۴۵۵۲	۰.۲۳۰۷۱
FCM	۸	۰.۲۸۱۳۴	۰.۲۷۶۵۸	۰.۲۴۳۳۱	۰.۲۳۷۲۴	۰.۲۴۷۳۶	۰.۲۳۸۹۲

جدول ۲۰.۳: ادامه میزان خطای مجموعه داده Balancescale

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۷	۰.۲۷۱۸۳	۰.۲۵۸۲۲	۰.۲۷۱۰۹	۰.۲۵۶۹۵	۰.۲۶۹۱۶	۰.۲۵۴۰۷
MCLA	۷	۰.۲۷۲۳۲	۰.۲۶۱۴۶	۰.۲۷۰۰۶	۰.۲۵۶۱۴	۰.۲۶۰۹۶	۰.۲۴۹۸۸
HGPA	۷	۰.۲۷۲۶۱	۰.۲۶۲۸۵	۰.۲۶۸۵۴	۰.۲۵۶۴۶	۰.۲۷۰۲۶	۰.۲۵۸۶۹
EM	۷	۰.۲۵۴۹۳	۰.۲۳۹۴۶	۰.۲۵۴۹۱	۰.۲۳۹۸۹	۰.۲۵۲۹۴	۰.۲۳۹۸۱
FCM	۷	۰.۲۷۶۷۸	۰.۲۶۹۹۵	۰.۲۶۶۹۱	۰.۲۳۲۶۲	۰.۲۴۵۸۵	۰.۲۳۳۲۲
CSPA	۶	۰.۲۸۲۵۲	۰.۲۶۸۰۴	۰.۲۸۳۰۲	۰.۲۶۸۵۴	۰.۲۷۴۷۵	۰.۲۶۱۵۶
MCLA	۶	۰.۲۸۱۶۶	۰.۲۶۶۲۳	۰.۲۷۶۷۲	۰.۲۶۱۱۲	۰.۲۶۹۸۲	۰.۲۵۳۷۱
HGPA	۶	۰.۲۸۱۶	۰.۲۶۷۸۸	۰.۲۷۹۲۱	۰.۲۶۸۰۹	۰.۲۷۸۳۸	۰.۲۶۴۹۷
EM	۶	۰.۲۶۲۴۲	۰.۲۴۳۲۳	۰.۲۶۹۱۴	۰.۲۴۹۹۴	۰.۲۶۰۷۱	۰.۲۴۵۲۸
FCM	۶	۰.۲۷۹۲۹	۰.۲۷۰۵۴	۰.۲۵۰۲۴	۰.۲۳۶۷۱	۰.۲۵۱۷۹	۰.۲۳۶۵۳
CSPA	۵	۰.۲۹۴۹۱	۰.۲۸۲۰۲	۰.۲۹۱۳۹	۰.۲۷۶۴۵	۰.۲۹۰۹۱	۰.۲۷۶۲۳
MCLA	۵	۰.۲۹۵۳۸	۰.۲۸۲۷۷	۰.۲۹۱۷۸	۰.۲۷۳۰۵	۰.۲۸۷۱۹	۰.۲۷۳۶۹
HGPA	۵	۰.۲۹۸۹۴	۰.۲۷۹۳۶	۰.۲۸۸۸۸	۰.۲۷۶۵۸	۰.۲۹۰۸	۰.۲۷۱۳۱
EM	۵	۰.۲۷۸۹۸	۰.۲۶۰۵۷	۰.۲۶۸۵۴	۰.۲۴۹۹۳	۰.۲۸۹۲۹	۰.۲۶۶۴۷
FCM	۵	۰.۲۸۲۸۳	۰.۲۶۷۸۸	۰.۲۹۸۹۱	۰.۳۰۰۵۵	۰.۳۰۱۸۲	۰.۳۰۵۴۶

جدول ۲۱.۳: ادامه میزان خطای مجموعه داده Balancescale

نام الگوریتم	C	خطای نمونه‌های آموزشی $m = 2$	خطای نمونه‌های آزمایشی $m = 2$	خطای نمونه‌های آموزشی $m = 2.5$	خطای نمونه‌های آزمایشی $m = 2.5$	خطای نمونه‌های آموزشی $m = 2.9$	خطای نمونه‌های آزمایشی $m = 2.9$
CSPA	۴	۰.۳۰۹۶۵	۰.۲۹۳۹۲	۰.۳۱۲۱	۰.۲۹۵۷۱	۰.۳۰۶۴۱	۰.۲۹۰۲۹
MCLA	۴	۰.۳۰۹۲	۰.۲۹۰۵	۰.۳۰۹۹۶	۰.۲۹۶۷	۰.۳۰۶۲۱	۰.۲۹۰۵۸
HGPA	۴	۰.۳۱۴۷۲	۰.۲۹۶۱۹	۰.۳۱۷۸۸	۰.۲۹۷۶۴	۰.۳۰۶۷۳	۰.۲۹۵۸۵
EM	۴	۰.۳۱۷۸۳	۰.۲۹۵۱۷	۰.۳۰۰۱	۰.۲۷۶۸۷	۰.۲۹۵۱۸	۰.۲۶۵۱
FCM	۴	۰.۲۸۰۱۵	۰.۲۷۴۶	۰.۳۲۲۳۸	۰.۳۲۵۶۶	۰.۳۲۵۱۹	۰.۳۲۷۴۲
CSPA	۳	۰.۳۳۰۶۸	۰.۳۱۷۱۲	۰.۳۳۳۴۳	۰.۳۲۰۵۷	۰.۳۳۹۱۵	۰.۳۲۶۱۶
MCLA	۳	۰.۳۲۹۹۳	۰.۳۰۸۳۶	۰.۳۲۵۸۵	۰.۳۰۴۷۵	۰.۳۴۰۵۳	۰.۳۲۶۲۷
HGPA	۳	۰.۳۳۳۰۶	۰.۳۱۷۱۹	۰.۳۳۳۹	۰.۳۲۰۹۸	۰.۳۳۰۳۸	۰.۳۱۵۰۱
EM	۳	۰.۳۳۴۵۶	۰.۳۱۴۹	۰.۳۴۰۸۱	۰.۳۲۱۲۷	۰.۳۳۰۲۶	۰.۳۱۱۷
FCM	۳	۰.۳۷۴۹۲	۰.۳۵۹۲۸	۰.۳۶۱۵۵	۰.۳۴۷۸۹	۰.۳۵۷۹۵	۰.۳۵۱۰۳
CSPA	۲	۰.۳۵۶۶۸	۰.۳۴۲۸۹	۰.۳۵۵۱۱	۰.۳۴۷۰۳	۰.۳۵۶۷	۰.۳۴۲۲۶
MCLA	۲	۰.۳۶۲۹۹	۰.۳۴۴۱۸	۰.۳۶۰۰۲	۰.۳۴۳۳۸	۰.۳۶۳۸۳	۰.۳۴۳۱۲
HGPA	۲	۰.۳۵۵۹۶	۰.۳۴۴۹۸	۰.۳۵۹۸۵	۰.۳۴۱۷۲	۰.۳۶۰۵۱	۰.۳۴۴۹۸
EM	۲	۰.۳۶۷۸۷	۰.۳۴۷۰۵	۰.۳۶۷۷۴	۰.۳۴۶۷۹	۰.۳۷۵۶۷	۰.۳۵۷۰۱
FCM	۲	۰.۳۸۸۳۹	۰.۳۸۵۶۴	۰.۳۸۲۰۱	۰.۳۷۲۶۳	۰.۳۷۷۸۸	۰.۳۶۴۲۹

#### ۴- نتیجه‌گیری

مجموعه داده‌های حجیم و پیچیده و در مسائل مختلف طبقه‌بندی و پیش‌بینی، در این پژوهش، رویکردی جدید با استفاده از روش‌های خوشه‌بندی، طبقه‌بندی و محاسبات گرانشی معرفی شده است. این روش، موارد مهم در مسئله یادگیری قانون مانند دقت قوانین استخراج‌شده، تعداد

از اهداف اصلی این تحقیق می‌توان به ارائه یک روش جدید برای یادگیری قوانین اشاره کرد. به دلیل اهمیت مسئله یادگیری قوانین به‌خصوص در



کارایی الگوریتم پیشنهادی در مقایسه با روش‌های پیشین در جدول ۲۳.۳ بیان شده است.

بر اساس نتایج به دست آمده از راهکار جدید در این مقاله، مهم‌ترین موضوعات پیشنهادی برای مسئله یادگیری قوانین در پژوهش‌های آتی عبارتند از:

- استفاده از روش‌های خوشه‌بندی متفاوت برای تشکیل یک الگوریتم ترکیبی به طوری که کارایی الگوریتم حفظ شود یا افزایش یابد.
- استفاده از دیگر روش‌های الگوریتم فازی-C میانگین برای محاسبه میزان خطای الگوریتم از جمله روش‌های مرتبه اول تاکاگی سوگنو و مرتبه دوم تاکاگی سوگنو
- استفاده از دیگر روش‌ها محاسبات گرانولار برای تبدیل مجموعه داده‌ها به اطلاعات گرانولی

جدول ۲۳.۳: کارایی الگوریتم پیشنهادی و روش‌های پیشین

مرجع	توانایی پردازش داده‌ها با مقادیر گسسته و پیوسته	غیرقطعی	پردازش داده‌های نویزی	کاهش میزان خطا
[11]	×	✓	✓	×
[13]	✓	✓	✓	×
[14]	✓	×	×	×
[15]	✓	×	×	×
[25]	✓	✓	×	×
HIGCRL	✓	✓	✓	✓

## ۵- مراجع

- [۱] Park, S., Piramuthu, S., Shaw, M., Dynamic Rule Refinement in Knowledge- Based Data Mining, Decision Support Systems Journal, 31(2), pp. 205-222, 2001.
- [۲] Ruckert, U., Kramer, S., A Static Approach to Rule Learning, ICML'06 Proceedings of the 23rd International Conference on Machine Learning, pp. 785-792, New York, NY, USA, 2006.
- [۳] Mark, N., Changing Monetary Policy Rules, Learning, and Real Exchange Rate Dynamics, Journal of Money, Credit and Banking, 41(6), pp. 1047- 1070, 2009.
- [۴] M. I. Nye, A. Solar-Lezama, J. B. Tenenbaum and B. M. Lake, "Learning compositional rules via neural program synthesis", 2020.
- [۵] Araki, Brandon, et al. "Learning Policies by Learning Rules." *IEEE Robotics and Automation Letters* 7.2 (2021): 1284-1291.
- [۶] Niu, Jiaojiao, et al. "A dynamic rule-based classification model via granular computing." *Information Sciences* 584 (2022): 325-341.
- [۷] Liu, Han, and Mihaela Cocea. "Granular computing-based approach of rule learning for binary classification." *Granular Computing* 4.2 (2019): 275-283.

کم قوانین به دست آمده و سرعت اجرای بالا را فراهم کرده است. با استفاده از محاسبات گرانولار کاهش افزونگی در داده‌ها اتفاق می‌افتد که می‌تواند استخراج قوانین با دقت بالاتر و تعداد کم را موجب شود. الگوریتم پیشنهادی در واقع یک روش جدید خوشه‌بندی ترکیبی را ارائه کرده است که نتایج آن در بیشتر مواقع با افزایش میزان دقت، بهتر از روش فازی C- میانگین است. در این راهکار، مراکز خوشه‌ها به عنوان قوانین تصمیم‌گیری در نظر گرفته شده و سپس از الگوریتم فازی C- میانگین با روش حداقل مربعات خطا برای یادگیری قوانین استفاده شده است. روش پیشنهادی، طبق نتایج عملی به دست آمده، موجب کاهش میزان خطای یادگیری شده است. همچنین در راستای این تحقیق از الگوریتم‌های EM، HGPA، CSPA، MCLA و FCM برای خوشه‌بندی و سپس یادگیری قوانین استفاده شده است. علاوه بر انجام آزمایش بر روی خوشه‌بندی ترکیبی پیشنهادی، بر روی تک‌تک این الگوریتم‌ها که برای اولین بار برای یادگیری قوانین با الگوریتم فازی C- میانگین حداقل مربعات خطا استفاده می‌شده، آزمایش‌هایی انجام شده و نتایج آنها با الگوریتم فازی C- میانگین مقایسه شده است. در واقع در الگوریتم پیشنهادی، ابتدا مجموعه داده‌ها با سه الگوریتم خوشه‌بندی مبتنی بر اجماع، الگوریتم پیشینه انتظار و فازی C- میانگین خوشه‌بندی شده‌اند. نتایج خوشه‌ها توسط الگوریتم ترکیبی ارزیابی می‌گیرد. الگوریتمی که خوشه‌های آن بیشترین شباهت با بقیه الگوریتم‌ها داشته باشد انتخاب می‌شود. از بین خوشه‌های الگوریتم انتخابی، خوشه‌ای که در آن بیشترین تجمع نمونه داده‌ها دیده شود به عنوان اولین خوشه الگوریتم ترکیبی در نظر گرفته می‌شود. سپس مرکز هر خوشه به عنوان قانون استخراج شده از خوشه‌ها در نظر گرفته می‌شود و به عنوان ورودی‌های الگوریتم فازی C- میانگین برای یادگیری قوانین ارسال می‌گردند.

الگوریتم خوشه‌بندی فازی C- میانگین برای یادگیری قوانین مورد استفاده قرار می‌گیرد. در این الگوریتم از روش کمترین مربعات خطا برای محاسبه میزان خطای الگوریتم استفاده می‌شود. استفاده از محاسبات گرانولار در سال‌های اخیر با پیشرفت روزافزون در مسائل هوشمند همراه بوده است و مجموعه داده‌هایی که به صورت نادقیق و مبهم هستند را پردازش می‌کند. همچنین روش پیشنهادی، راهکار بسیار خوبی در مواجهه با هر نوع داده‌ی برجسب‌دار و بدون برجسب معرفی کرد و نشان داد که استفاده از ترکیب یادگیری، موجب بهبود یادگیری خواهد شد. الگوریتم پیشنهادی یک راهکار جدیدی که قبلاً ارائه نشده بود را مطرح کرده است. همان‌طور که در بخش قبلی مقایسه شده است و با توجه به جداول زیر می‌توان نتیجه گرفت که الگوریتم پیشنهادی نتایج مطلوبی نسبت به روش‌های قبلی داشته است.

جدول ۲۲.۳: میزان دقت الگوریتم GBAC [۵] و HIGCRL با تعداد خوشه ۲

مجموعه داده‌ها	میزان دقت	میزان دقت
	HIGCRL	GBAC
Pima	۶۴%	۷۸%
Bupa	۸۵%	۷۵%
Haberman	۵۷%	۷۷%

[22] Z.Pawlak. Rough sets: theoretical aspects of reasoning about data, system theory, Knowledge Engineering and Problem Solving. Kluwer, Netherlands. (vol.178, pp.3577-3594). (2008).

[23] Blake, Catherine. UCI repository of machine learning databases. <http://www.ics.uci.edu/~mllearn/MLRepository.html>. (1998).

[24] Al-Shammaa, Mohammed, and F.Maysam . Automatic generation of fuzzy classification rules using granulation-based adaptive clustering. (2015).

[25] W.Pedrycz, H.Izakian. Cluster-centric fuzzy modeling. IEEE transactions on fuzzy systems (Vol.22, pp.1585-1597). (2014).



فرناز ماهان دانشیار گروه علوم کامپیوتر دانشگاه تبریز است. نامبرده مدرک کارشناسی ارشد و دکتری تخصصی خود را به ترتیب در رشته مهندسی کامپیوتر - هوش مصنوعی و ریاضیات در ۱۳۸۴ (دانشگاه علم و صنعت ایران، تهران، ایران) و علوم کامپیوتر - سیستم‌های کامپیوتری در ۱۳۹۳ (دانشگاه تبریز، تبریز، ایران) اخذ کرده است. علایق تحقیقاتی او بازسازی سیستم قدرت، هوش مصنوعی و ریاضیات، محاسبات شبکه، و سیستم‌های چند عملی است. نشانی رایانامه ایشان عبارت است از: [mahan@tabrizu.ac.ir](mailto:mahan@tabrizu.ac.ir)



صالح صلحی کارشناس ارشد علوم کامپیوتر دانشگاه تبریز است. نامبرده مدرک کارشناسی ارشد خود را در رشته علوم کامپیوتر در ۱۳۹۷ (دانشگاه تبریز، تبریز، ایران) اخذ کرده است. علایق تحقیقاتی او محاسبات گرانولار، یادگیری ماشین و یادگیری قوانین است. نشانی رایانامه ایشان عبارت است از: [salehsolhi@yahoo.com](mailto:salehsolhi@yahoo.com)



سید میثم روضه خوانی دانشجوی دکتری تخصصی علوم کامپیوتر دانشگاه تبریز است. او مدرک کارشناسی خود را در رشته علوم کامپیوتر از دانشگاه محقق اردبیلی و مدرک کارشناسی ارشد خود را در همین رشته از دانشگاه تبریز دریافت کرده است. علایق تحقیقاتی او بر محاسبات ابری، محاسبات گرانولار، داده کاوی و یادگیری ماشین متمرکز است. وی در تمامی مقاطع تحصیلی عضو گروه دانشجویان استعداد درخشان بوده است. نشانی رایانامه ایشان عبارت است از: [m.roozekhanii@tabrizu.ac.ir](mailto:m.roozekhanii@tabrizu.ac.ir)

[۸] Pedrycz, W. "Analysis and design of intelligent systems: A framework of granular computing." (2013).

[۹] Mahan, Farnaz, et al. "Chi-MFlexDT: Chi-square-based multi flexible fuzzy decision tree for data stream classification." Applied Soft Computing 105 (2021): 107301.

[۱۰] Rozezhkhanii, Seyyed Meysam, and Farnaz Mahan. "VM consolidation improvement approach using heuristics granular rules in cloud computing environment." Information Sciences 596 (2022): 15-29.

[۱۱] Gogoi, Prasanta, Dhruva, K. Bhattacharyya, and K. Kalita. A rough set-based effective rule generation method for classification with an application in intrusion detection. International Journal of Security and Networks (vol.8, pp.61-71). (2013).

[۱۲] N.Ibrahim, H.Mustapha, A.Rosli. Hybrid Model of Hierarchical Clustering and Decision Tree for Rule-based Classification of Diabetic Patients. International Journal of Engineering and Technology. (Vol.5, pp.3986-3991). (2013).

[۱۳] Al-Shammaa, Mohammed, and F.Maysam . Automatic generation of fuzzy classification rules using granulation-based adaptive clustering. (2015).

[۱۴] J.Gama, P.Kosina. Learning decision rules from data streams. IJCAI Proceedings-International Joint Conference on Artificial Intelligence. (Vol. 22, pp.1255). (2011).

[15] بهزاد جعفری، عادل آذر. درخت تصمیم فازی، رویکردی نوین در تدوین استراتژی- پژوهش‌های مدیریت عمومی. (1394)

[16] J.Kennedy, R.Eberhart. Particle swarm optimization. Proceedings of International Conference on Neural Networks IV. (Vol. 1000, pp.1942-1948). (1995).

[17] Noroozibeyrami, Meybodi. Improving particle swarm optimization using fuzzy logic. Proceedings of the Second Iranian Data Mining Conference, Amir Kabir University of Technology, Tehran, Iran. (2008).

[18] JC.Bezdek, R Ehrlich. FCM: The fuzzy c-means clustering algorithm. Computers & Geosciences (Vol.10, 191-203). (1984).

[19] Fred, Ana, et al. Knowledge discovery, knowledge engineering and knowledge management. Springer International Publishing, 2020.

[20] de Campos Souza, Paulo Vitor, Edwin Lughofer, and Augusto Junio Guimaraes. "An interpretable evolving fuzzy neural network based on self-organized direction-aware data partitioning and fuzzy logic neurons." Applied Soft Computing 112 (2021): 107829.

[21] J.Hu, T.Li, H.Wang, and Fujita. Hierarchical cluster ensemble model based on knowledge granulation. Knowledge-Based Systems.(vol.91, 179-188). (2016).



جعفر رزم آرا دانشیار گروه علوم کامپیوتر دانشگاه تبریز است. او مدرک کارشناسی و کارشناسی ارشد خود را به ترتیب از دانشگاه صنعتی اصفهان و دانشگاه تربیت مدرس دریافت کرده است. نامبرده دکتری تخصصی خود را در رشته علوم کامپیوتر در ۱۳۹۰ (دانشگاه صنعتی مالزی، مالزی) اخذ کرده است. او قبلاً در دانشکده محاسبات دانشگاه تکنولوژی مالزی به عنوان مدرس ارشد بوده است. علایق اصلی تحقیقاتی او داده کاوی، محاسبات نرم و کاربردهای یادگیری ماشین به ویژه در بیوانفورماتیک و زیست شناسی محاسباتی است. نشانی رایانامه ایشان عبارت است از:

[razmaraj@gmail.com](mailto:razmaraj@gmail.com)