

تشخیص بیماری های مزمن کلیه با استفاده از ترکیب الگوریتم فازی خشن کسری بهبود یافته، k-MENS، خوش بندی و بهینه سازی ازدحام موش ها و مروری بر روش های استفاده شده در تشخیص بیماری های مزمن کلیوی

سید حسن نجات^۱، سید حسین هاشمی^۲، مهیار ثابت^۳ و محمد سردشتی فرد^۴

^۱ دانشگاه آزاد اسلامی واحد تهران مرکز-دکتری تخصصی کامپیوتر مهندسی نرم افزار

^۲ دانشگاه آزاد اسلامی واحد تهران مرکز-دکتری تخصصی کامپیوتر مهندسی نرم افزار

^۳ دانشگاه آزاد اسلامی واحد تهران مرکز-دکترا تخصصی مدیریت

^۴ دانشگاه آزاد اسلامی واحد ملارد-کارشناسی ارشد مهندسی نرم افزار

چکیده

اطلاعات مقاله

در این مقاله، پیش‌بینی و طبقه‌بندی بیماری مزمن کلیوی مبتتنی بر داده‌های بزرگ Hadoop با استفاده از خوش‌بندی K-means فازی خشن کسری (IF-RFKM) و XG تقویت کننده ازدحام موش ها پیشنهاد شده است. در اینجا، روش خوش بندی IF-RFKM در نظر گرفته شده است برای پیش‌بینی بیماری این بیماری با استفاده از طبقه‌بندی تقویت کننده XG طبقه‌بندی می‌شود طبقه‌بندی مراحل بیماری های مزمن کلیوی به عنوان طبیعی و غیر طبیعی الگوریتم بهینه سازی ازدحام موش (RSO) برای بهینه سازی پارامترهای پیشنهاد شده است طبقه‌بندی XGboost در ابتداء، داده ها به طور تصادفی از مجموعه داده های CKD تولید می شوند

شبیه سازی به زبان python انجام شده است. از شبیه سازی، روش پیشنهادی به دقت بالاتر ۹۹,۵۷٪، ۹۸,۲۸٪ و ۹۷,۳۵٪، فرآخون بالاتر ۹۸,۲۳٪، ۹۸,۳۴٪، ۹۰,۲۵٪، ۹۲,۱۵٪ و ۹۲,۴۸٪ در مقایسه با روش های همانند تشخیص بیماری مزمن کلیوی و طبقه‌بندی با حذف ویژگی های بازگشتی با استفاده از درخت تصمیم موجود بدست آمده است. روش استفاده شده طبقه‌بندی و خوش بندی بیماری با استفاده از رگرسیون لجستیک (CCKD-LR) و طبقه‌بندی بیماری مزمن کلیه با استفاده از دستگاه ناقل پشتیبانی چند هسته ای با (CCKD-MKC-SVM) بکار برده شده است.

تاریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۱/۱۰/۰۵

تاریخ پذیرش مقاله: ۱۴۰۱/۱۱/۰۷

تاریخ انتشار مقاله: ۱۴۰۱/۱۱/۲۰

کلمات کلیدی:

تشخیص

بیماری

کلیه

الگوریتم فازی

ازدحام موش ها

خوش بندی

کلان داده

k-MENS

۱ - مقدمه

بررسی قرار می گیرند. روش‌های داده‌کاوی و روش‌های یادگیری ماشین، روش‌ها و ابزارهایی را برای اصلاح این داده‌های مختلف به عنوان داده‌های نتیجه‌ای برای تصمیم‌گیری توزیع می‌کنند.

روش‌ها با یادگیری نیمه نظارتی و همچنین یادگیری بدون نظارت مورد بررسی قرار گرفته‌اند. نیمه نظارت گروهی از استراتژی‌های یادگیری ماشینی است که با یادگیری یک تکنیک، از نمونه

های برچسب دار و بدون برچسب استفاده می‌کند.

اساساً یادگیری بدون نظارت جایگزین خوش بندی است. به طور کلی، خوش بندی راه حلی برای کلاس‌های آشکار شده در داده‌ها است. خوش بندی یک روش رایج برای تجزیه و تحلیل عددی داده‌ها و همچنین تکنیکی از داده‌های بدون نظارت است. به طور معمول در زمینه کاربردهای پژوهشی می‌توان از خوش بندی برای پیش‌آگهی بیماری‌های مختلف استفاده کرد. از بین بیماری‌های مختلف، بیماری مزمن کلیه یک بیماری قابل توجه برای عموم مردم است.

CKD وضعیتی است که در آن کلیه‌ها آسیب می‌بینند و نمی‌توانند خون را آنطور که باید فیلتر کنند. به همین دلیل، مایعات اضافی و مواد زائد خون در بدن باقی می‌مانند و ممکن است باعث مشکلات سلامتی دیگری مانند بیماری قلبی و سکته شود. در مرگ در عملکرد کلیه، CKD نیز نتیجه متقابله را آغاز می‌کند. افراد مبتلا به CKD از این بیماری رنج می‌برند که عملکرد کلیه را کاهش می‌دهد. علاوه بر این، باعث ایجاد اختلالات اضافی مانند تغذیه نامناسب، استخوان‌های ضعیفتر، لذت خون بالا، کم‌خونی، آسیب عصبی می‌شود. در این بین، بیماری کلیوی خطر ابتلای بیمار به بیماری قلبی را در کنار بیماری‌های خونی افزایش می‌دهد. ارثی، پرفشاری خون و دیابت نیز توسط CKD منشاء می‌گیرند. پیش‌آگهی زودرس CKD برای درمان مناسب برای جلوگیری از نارسایی کلیه ضروری است.

پیش‌بینی‌های اولیه از طریق رویکردهای یادگیری ماشینی، مانند SVM، Naïve Bayes و غیره انجام می‌شوند. جنبه داده می‌تواند توسط طبقه‌بندی کننده برای پیش‌آگهی CKD ساخته شود.

در طول دهه‌های گذشته، مدل‌های داده کاوی متعددی برای تشخیص بیماری مزمن کلیوی پیشنهاد شده‌اند. کاربرد مدیریت دانش به دلیل کارایی آن در طول طبقه‌بندی در امتداد پیش‌بینی بیماری به سرعت در بخش‌های مراقبت‌های بهداشتی در حال رشد است و برای تجزیه و تحلیل تعداد زیادی از داده‌ها ضروری است. برای این منظور، داده کاوی تأثیر قابل توجهی برای افزایش تحقیقات پژوهشی می‌گذارد. علاوه بر این، رویکردها به

امروزه فناوری‌ها با تغییرات اساسی توسعه یافته‌اند که منجر به بهبود فناوری‌هایی با حجم عظیم داده می‌شود. اگر از داده‌ها استفاده نشود، به مقدار داده ای تبدیل می‌شود که قابل استفاده نیست. بنابراین، در صورتی که با استفاده از روشی به نام داده کاوی به درستی مدیریت شوند، مقداری از داده‌های غیرقابل استفاده می‌توانند به عنوان یک مبنای داده بسیار ارزشمند استفاده شوند.

داده کاوی برای کشف طرح کلی محرك از اطلاعات در یک پایگاه داده پنهان استفاده می‌شود. با استفاده از تکنیک‌های یادگیری ماشینی و محاسبات آماری، کشف الگو برای ساخت مدل‌هایی آماده می‌شود که عملکرد داده‌ها را پیش‌بینی می‌کنند. طبقه‌بندی تکنیکی برای کشف الگوها از داده‌ها با حجم عظیمی از داده‌ها به سرعت توسط تکنیک داده کاوی تجزیه و تحلیل می‌شوند، در واقع، در زمینه آمار، تجارت، پیش‌بینی و مهندسان ارتباطات، داده کاوی تکنیک پیشرفته‌ای نیست که از الگوها در جستجوی داده‌ها برای پیش‌بینی، تأیید و شناسایی استفاده کند. در حال حاضر پایگاه‌های بالینی پژوهشی زیادی بر اساس پیشرفت سیستم مدیریت پایگاه داده سلامت ایجاد شده است. با تکنیک‌های داده کاوی، پایگاه‌های داده ترکیبی به راحتی حفظ و نگهداری و قابل استفاده می‌شوند.

داده کاوی برای شناسایی بیماری از پرونده داده‌های پژوهشی بیمار در بخش مراقبت‌های بهداشتی به کار می‌رود. طبقه‌بندی یک استراتژی داده کاوی است. طبقه‌بندی بیزی، درخت تصمیم، شبکه‌های عصبی، رگرسیون لجستیک، ماشین‌های بردار پشتیبان نمونه‌هایی از تکنیک‌های طبقه‌بندی هستند. برای پیش‌بینی و طبقه‌بندی، درخت تصمیم به عنوان رایج‌ترین تکنیک مورد استفاده قرار گرفته می‌شود.

در فرآیند جستجو، طبقه‌بندی می‌تواند برای نمایش‌ها یا توابع معمولی استفاده شود که کلاس‌های داده یا طبقه‌بندی را تمایز می‌کند، با این هدف که این تکنیک بتواند برای محاسبه دقیق کلاس‌های هدف استفاده شود. نمونه‌ای از روش طبقه‌بندی در فناوری، طبقه‌بندی تهدیدات در توسعه نرم افزار است. همچنین در طرح مراقبت از سلامت انسان، فناوری ارتباط با اطلاعات دارای شهرد اضافی است. طرح رعایت بهداشت و علم پژوهشی می‌تواند درآمد و آورده‌های هنگفتی را روز به روز ایجاد کند. روش‌های تجزیه و تحلیل پژوهشی و ارائه دهنده خدمات بهداشتی، حجم عظیمی از داده‌ها از جمله صدا، متن، ویدئو، تصویر، که قابل مدیریت بوده و بسیار مشکل ساز بوده و با روش‌های مرسوم مورد

- کارایی روش پیشنهادی با روش های موجود مانند CCKD-MKC، CCKD-LR، CCKD-RFE-DT مقایسه می شود.

ماقی این مقاله به این صورت طراحی شده است: بخش ۲ مطالعات اخیر را مرور می کند، بخش ۳ در مورد روش پیشنهادی توضیح می دهد، بخش ۴ اثبات می کند. نتیجه با بحث، بخش ۵ این مقاله را به پایان می رساند.

۲- مرور مطالعات اخیر

بسیاری از مطالعات مربوط به مدل تحلیلی Hadoop-big data برای پیش‌بینی و طبقه‌بندی بیماری‌های مزمن کلیوی در ادبیات پیشنهاد شده‌اند، برخی از مطالعات اخیر در اینجا مرور می‌شوند. پیشنهاد شده‌اند، برخی از مطالعات اخیر در اینجا مرور می‌شوند. Perumal و Jerlin Rubini یک طبقه‌بندی بیماری مزمن کلیوی را با استفاده از دستگاه بردار پشتیبان چند هسته با رویکرد بهینه‌سازی مگس میوه پیشنهاد کرده‌اند. از مجموعه قابل دسترس FFOA برای انتخاب توابع بهینه به کار گرفته شد. توابع از طریق مجموعه داده‌های پزشکی برای پیش پردازش انتخاب شدن و به ماشین بردار پشتیبان چند هسته برای طبقه‌بندی داده‌های بالینی داده شدند. پیامد تحلیلی مشخص می‌کند که روش طبقه‌بندی CKD ارائه شده به ارزش دقیق طبقه‌بندی می‌رسد.

نیتیا و همکاران CCKD-KKMC-NNC-CSOA را برای طراحی و بهبود روشی برای تشخیص CKD با استفاده از مجموعه ای از طبقه بندی پیشنهاد کرده اند. از جمله روش خوش بندی. در عمل و تشكیل درمان برای تصاویر سونوگرافی و ام آر آی، شناسایی سنگ کلیه با قطعه بندی تکنیک ضروری بود. در تصاویر سونوگرافی، تقسیم سنگ کلیه اغلب به صورت فیزیکی در آموزش پزشکی انجام می شد. با استفاده از طبقه‌بندی کننده شبکه عصبی، تصاویر به عنوان عادی و غیرعادی طبقه‌بندی شدند. تصاویر غیرطبیعی به فاز تقسیم‌بندی برای تقسیم تومور با ناحیه سنگ به صورت جداگانه با استفاده از رویکرد خوش‌بندی چند کرنل - K means مشخص شدند.

Jeyakumar و Pradeepa خود تنظیم کارآمد برای پیش‌بینی بیماری مزمن کلیوی ارائه کرده‌اند. یک خوش‌بندی طیفی خود تنظیم برای کاهش اندازه‌گیری بالا و مسائل اضافی در داده‌ها ارائه شد. قرار گرفتن در معرض استخراج همراه با ایجاد اطلاعات ضروری شناخته شده از

متخصصان بالینی در فرآیند تصمیم گیری کمک می کنند. بسیاری از داده های مراقبت های بهداشتی با ابزارهای پایگاه داده بزرگ ترکیب می شوند. حالت های تحلیلی به داده های جمع آوری شده برای حمایت از پیش‌بینی دقیق بیماری ها در سیستم های مراقبت بهداشتی بستگی دارد. علاوه بر این، چالش های مختلفی در طول تجزیه و تحلیل داده های بزرگ از طریق برنامه های کاربردی مختلف مراقبت های بهداشتی به وجود می آید. این اشکالات باعث الهام گرفتن این کار شده است.

یک روش خوش‌بندی IF-RFKM در این مقاله برای پیش‌بینی و طبقه‌بندی بیماری مزمن کلیوی پیشنهاد شده است. این بیماری با استفاده از طبقه‌بندی کننده XG boost طبقه‌بندی می‌شود تا مراحل بیماری‌های مزمن کلیوی را به صورت نرمال و غیرطبیعی طبقه‌بندی کند. علاوه بر این، برای بهینه‌سازی پارامترهای طبقه‌بندی کننده تقویت XG، الگوریتم بهینه‌سازی ازدحام مoshها پیشنهاد شده است.

مشارکت های اصلی این مقاله عبارتند از:

- پیش‌بینی و طبقه‌بندی بیماری‌های مزمن کلیوی مبتنی بر داده‌های بزرگ Hadoop با استفاده از خوش‌بندی IF-RFKM و بهینه‌ساز ازدحام مosh‌های صحرابی تقویت کننده (IF-RFKM-XG-RSO) XG پیشنهاد شده است.

حال تحلیلی مبتنی بر داده های بزرگ پیشنهادی، تکنیک داده کاوی پیشرفته از جمله خوش بندی، یادگیری ماشین، رویکردهای بهینه سازی را ترکیب می کند.

- روش خوش‌بندی IF-RFKM برای پیش‌بینی بیماری مزمن کلیوی در نظر گرفته می‌شود.
- این بیماری با استفاده از طبقه‌بندی XGboost 21 برای طبقه‌بندی مراحل بیماری‌های مزمن کلیوی به عنوان نرمال و غیر طبیعی طبقه‌بندی می‌شود.
- برای بهینه‌سازی پارامترهای طبقه‌بندی کننده تقویت XG، الگوریتم بهینه‌سازی ازدحام مosh‌ها ۲۲ پیشنهاد شده است.

- داده ها به طور تصادفی از مجموعه داده های بیماری مزمن کلیه تولید می شوند.
- روش پیشنهادی در پایتون فعال می‌شود، عملکرد آن با معیارهای عملکرد مانند دقت، امتیاز F1، دقت، یادآوری بررسی می‌شود.

یادگیرنده پایه، بهبود عملکرد مجموعه فن آوری ها، از جمله K-Neighbors و درخت تصمیم. برای رسیدگی به مقادیر از دست رفته، پیش پردازش داده ها و همچنین افزایش داده ها برای عادی سازی انواع الگوهای آزاد شده پذیرفته شد.

۳- روش پیشنهادی

در این مقاله، پیش‌بینی و طبقه‌بندی بیماری‌های مزمن کلیوی IF-RFKM و بهینه‌ساز ازدحام موش‌های تقویت کننده (CCKD) با استفاده از خوش‌بندی Hadoop بر داده‌های بزرگ (IF-RFKM-XG-RSO) پیشنهاد شده است. بلوک دیاگرام روش پیشنهادی CCKD-IF-RFKM-XG-RSO در شکل ۱ آورده شده است.

داده کاوی:

داده های بزرگ برای ذخیره حجم زیادی از داده ها برای هدف معین ذخیره می شود. این استراتژی‌های داده کاوی عمدتاً در زمینه پژوهشی به کار می‌روند، که به پزشکان امکان می‌دهد در حین پردازش تصمیم‌گیری، اطلاعات مربوطه را به دست آورند. الگوها توسط فرآیند داده کاوی از داده ها استخراج می شوند. بر اساس ویژگی های داده کاوی، الگوها برای مجموعه داده ایجاد می شوند. توصیفی و پیشگویی دو جنبه مهم داده کاوی هستند که در آنها توصیفی به شناسایی مجموعه داده های معمولی کمک می کند. پیش‌بینی کننده بسیاری از پیش‌بینی‌ها را از نظر مجموعه داده‌های قابل دسترس انجام می‌دهد. داده کاوی به پارامترهای خاصی نیاز دارد، یعنی تجزیه و تحلیل الگو، طبقه‌بندی، خوش‌بندی، توالی، ارتباط برای ارزیابی داده ها، که در آن، تداعی نشان دهنده الگوهایی است که ارتباط بین داده ها را تعیین می کند، به همین ترتیب، طبقه‌بندی نشان دهنده الگوهای جدید از نظر اهداف از پیش تعریف شده است. این خوش‌های شامل اجسام کوچکی است که شبیه یکدیگر هستند.

K-means خشن کسری بهبود یافته برای خوش‌بندی:

در این بخش اطلاعات کلان داده‌های طولی را توصیف می‌کند که از روش‌های تصویربرداری غیرنهاجمی با استفاده از رویکرد K-means فازی کسری (IF-RFKM) بهبود یافته خوش‌بندی شده‌اند. IF-RFKM یک روش شناخته شده است که در پیش‌بینی بیماری استفاده می‌شود.

داده های بیماران بالینی و همچنین آزمایشگاهی بود که حداقل حمایت برای کمک به جراحان در افزایش دقت شناسایی CKD قبلًا بر سطح جدی تأثیر می گذاشت. نتایج خوش‌بندی از روش‌های یادگیری ماشینی استفاده شد، یعنی ماشین بردار پشتیبان، شبکه عصبی مصنوعی، شبکه عصبی عمیق، نزدیک‌ترین همسایه K و جنگل تصادفی مورد استفاده قرار گرفته است.

Akben سطح اولیه CKD را با استفاده از مدل های داده کاوی برای آزمایش ادرار، آنالیز خون، وقایع بیماری ارائه کرده است. روش ارائه شده از تجزیه و تحلیل پژوهشی با استفاده از نتایج مربوط به بیماری، ادرار و آزمایش خون پشتیبانی می کند. برای طبقه‌بندی الگوریتم از تکنیک داده کاوی استفاده شد. مرحله اولیه روش استخراج، پیش پردازش بر روی داده های CKD انجام شد. پیش پردازش را می توان با روش خوش‌بندی K-means انجام داد. برای تشخیص CKD، مدل های طبقه‌بندی، مانند SVM، Naïve Bayes، KNN برای داده های از پیش پردازش شده کاربردی بودند.

Aldhyani و همکاران خوش‌بندی نرم را برای تقویت تحلیل بیماری‌های مزمن در الگوریتم‌های یادگیری ماشین ارائه کرده‌اند. هدف توسعه روش بررسی قرار گرفتن در معرض بیماری های مزمن بود که برای امنیت بقای مردم استفاده می شد. روش ارائه شده برای بهبود شناسایی بیماری مزمن با استفاده از الگوریتم یادگیری ماشینی ایجاد شده است.

Khamparia و همکاران طبقه‌بندی بیماری مزمن کلیوی را با یادگیری داده های چند رسانه ای با استفاده از سیستم رمزگذار خودکار پشتیه ای عمیق ارائه کرده اند. مدل یادگیری عمیق جدیدی برای طبقه‌بندی CKD با استفاده از رمزگذار خودکار پشتیه ای با طبقه‌بندی کننده Softmax پیشنهاد شد. برای استخراج توابع ارزشمند از طریق پایگاه داده، رمزگذار خودکار انباسته شده در نظر گرفته که توسط طبقه‌بندی کننده The Softmax برای محاسبه جلسه تکمیل استفاده شد. روش multi mode زده شده با دقت طبقه‌بندی های محافظه کار تخمین تلقی می شود.

Jongbo و همکاران رشد روش گروهی را برای تجزیه و تحلیل بیماری مزمن کلیوی ارائه کرده اند. که در آن، ۲ روش مشترک گنجانده شد یعنی بسته بندی و زیرفضای تصادفی بر روی ۳

عضویت فازی شی در حداقل تقریب با ۱ تخصیص داده شده و عضویت فازی جدید در معادله نمایش داده میشود.

$$\mu_{mk} = \begin{cases} \frac{1}{\sum_{j=1}^l \left(h_{mk}/h_{jk} \right)^{\frac{2}{n-1}}} & \text{if } A_k \in \hat{D}_m, \\ 1 & \text{if } A_k \in \bar{D}_m, \end{cases}$$

که در آن h_{mk} به معنای حداقل فاصله بین A_k در امتداد کل مراکز خوش است. اگر فاصله h_{jk} بین A_k وجود داشته باشد، انحراف فاصله $h_{jk}-h_{mk}$ کمتر از آستانه فعلی است و D_m نشان دهنده تعداد خوش است، عبارت فوق دارای مرزهای فازی واضح در خوش RFKM با تقریب کمتر است. اندازه‌گیری فازی محلی، شی مرزی را محاسبه می‌کند که متعلق به خوش‌های کمتر مرتبط است، در حالی که معیار فازی سراسری، هر شی را که به همه خوش‌ها تعلق دارد، محاسبه می‌کند. اگر شیء مرزی A_2 در بین خوش‌های ۱ و ۲ در محلی واقع شده باشد، عضویت فازی متعلق به خوش‌های ۱، ۲ است که به صورت محلی ارتقا یافته اند. این برای افزایش فازی محلی پاسخگو است. محاسبه مرکز خوش تکراری در معادله نمایش داده شده است.

$$U_m = \begin{cases} T_g \times \frac{\sum_{A_k \in D_m} \mu_{mk}^n A_k}{\sum_{A_k \in D_m} \mu_{mk}^n} + T_f \times \frac{\sum_{A_k \in \hat{D}_m} \mu_{mk}^n A_k}{\sum_{A_k \in \hat{D}_m} \mu_{mk}^n} & \text{if } D_m \neq \phi \wedge \hat{D}_m \neq \phi, \\ \frac{\sum_{A_k \in D_m} \mu_{mk}^n A_k}{\sum_{A_k \in D_m} \mu_{mk}^n} & \text{if } D_m \neq \phi \wedge \hat{D}_m = \phi, \\ \frac{\sum_{A_k \in D_m} \mu_{mk}^n A_k}{\sum_{A_k \in D_m} \mu_{mk}^n} & \text{if } D_m = \phi \wedge \hat{D}_m \neq \phi, \end{cases}$$

که در آن T_g و T_f نشان دهنده ضرایب وزنی اهمیت نسبی $>$ و 1 هستند. $T_g + T_f = 1$ مناطق مرزی معمولاً پایین تر است. پس از Rough K-Means برخی بهبودهای پیشرونده، روش کلاسیک RFKM انجام شد. A_k به شی در فاصله h_{mk} از مرکز um خوش D_m نیاز دارد. اشیاء در منطقه محدود کمتر مربوطه در امتداد درجات عضویت فازی متعدد قرار دارند. با استفاده از IF-RFKM پارامترهای خروجی از طریق سیستم فازی به دست می‌آیند.

IF-RFKM سریعتر از سایر روش‌های خوش بندی است، به خصوص اگر خوش ها کروی باشند. از این رو، تعداد زیادی پیکسل با کمک IF-RFKM خوش بندی می‌شوند. داده ها به عنوان مجموعه ای از خوش جدا می‌شوند. در اینجا، پارامترهای ورودی داده شده به واحد شفاف سازی ویژگی هایی را نشان می‌دهد که برای پیش‌بینی وجود یا عدم وجود بیماری مزمن کلیوی در نظر گرفته می‌شود. که در آن ۲۵ ویژگی مانند فشار خون، جاذبه دقیق، آلبومین، قند، سلول چرک، گلbul های قرمز، توده های سلول چرک، باکتری برای پیش‌بینی بیماری مزمن کلیوی در نظر گرفته می‌شود. سپس، متغیرهای خروجی از واحد فازی‌زدایی به پیش‌بینی وجود یا عدم وجود بیماری مزمن کلیوی اشاره دارد. پارامترهای فازی نتیجه به طور خودکار در تنظیم می‌شوند. پارامترهای توابع عضو را می‌توان با توجه به دامنه واریانس داده های ورودی همراه با نامشخص مشخص کرد. محاسبه فاصله اقلیدسی توسط درجات عضویت فازی که با معیارهای خاصی آغاز شده اند تغییر می‌کند. رویکرد خوش‌بندی $K\text{-means}$ با جداسازی داده‌ها عمل می‌کند، زیرا مرکزها توسط مجموعه‌ای از خوش‌ها تعیین می‌شوند. در این، خوش‌های ۱، ۲ در امتداد اشیاء مرزی مرتبط با آن نشان داده شده‌اند، از این نقطه، شی مرزی خوش ۱ با موقعیت خوش مرتبط با آن قرار دارد. اما، شی مرزی خوش ۲ در منطقه ای در میان خوش ۱، ۲ قرار می‌گیرد. این ها به طور تصادفی از مجموعه داده ها تولید می‌شوند. داده های بزرگ برای پیش‌بینی بیماری مزمن کلیه به طور تصادفی از مجموعه داده های CKD تولید می‌شود. درجه عضویت فازی توسط فرمول زیر محاسبه می‌شود.

$$\mu_{mk} = \frac{1}{\sum_{j=1}^l \left(h_{mk}/h_{jk} \right)^{\frac{2}{n-1}}},$$

که در آن پارامتر n تعداد فازی فایر (fuzzifier) را نشان می‌دهد و $\exists n \in (\infty, 1)$ درجات فازی مختلفی را ایجاد می‌کند، پارامتر μ درجه عضویت شی A_k به خوش D_m را نشان می‌دهد. در اینجا، $\mu \in [0, 1]$ و $\sum_{m=1}^l \mu_{mk} = 1$ ، پارامتر h_{mk} ماتریس فاصله را نشان می‌دهد. درجات عضویت فازی محدوده تغییرات ورودی را تعیین می‌کند که نشان دهنده ویژگی‌های پیش‌بینی بیماری مزمن کلیوی و سطح عدم قطعیت است که بر سطح تنوع مقادیر ویژگی دلالت دارد. اگر یک شی با تقریب حداقلی قرار گیرد، شی برای خوش های دیگر رقابت نمی‌کند. بنابراین، این درجه

شکل ۱ نمودار بلوکی برای حالت تحلیلی مبتنی بر داده های بزرگ پیشنهادی برای پیش بینی بیماری کلیوی با طبقه بندی

اجازه دهید پارامتر γ بردار ورودی را مشخص کند، b بردار خروجی را از طریق طرح فازی مشخص کند، bc خروجی ترجیحی را مشخص کند، ϑ بردار پارامترهای بعدی را مشخص کند.

$$C_a^{1-p} h(a) = \frac{1}{\Im(1-p)} \int_0^a (a-\tau)^{-p} \frac{c}{ca} h(\tau) c\tau,$$

مشتق h به عنوان p است، که در آن $(1-p)$ نشان دهنده تابع گاما و $h(a)$ نشان دهنده فاصله نرمال شده بین عنصر داده است، $h(\tau)$ نشان دهنده اشیاء در ناحیه مرزی است. پارامترهای متعاقب ϑ تنظیم برای کاهش زمان محاسبات و همچنین به دست آوردن تصمیم بهتر در معادله نشان داده شده است.

$$\vartheta = [t_1, \dots, t_N, \bar{t}_1, \dots, \bar{t}_N]^W.$$

در اینجا پارامتر تعداد قوانین را مشخص می کند. محدوده متغیر ورودی به بخش ها جدا می شود. درجه عضویت برای هر بخش در نظر گرفته می شود. پارامترهای درجه عضویت با توجه به محدوده متغیرهای ورودی در امتداد سطح نامشخص مورد بررسی قرار می گیرند. مقدار کلی قوانین معادل مقدار کلی درجات عضویت است. روش $IF-RFKM$ مزایای مجموعه های فازی مرتبه کسری و شبکه خوش بندی $RFKM$ را ارائه می دهد. این امکان خوش بندی کلان داده ماهراه را در حین پردازش تصمیم گیری فراهم می کند.

طبقه بندی **XGboost** برای طبقه بندی بیماری مزمن کلیوی:

در این مقاله طبقه بندی **XGboost** برای طبقه بندی بیماری مزمن کلیوی مورد بحث قرار گرفته است. **XGBoost** انتخاب شده است، زیرا بر تعدادی از معایب ناشی از روش های موجود غلبه می کند. به همین دلیل است که **XGBoost** به عنوان مدل طبقه بندی ترجیحی هنگام برخورد با مسائلی که با مشکلات

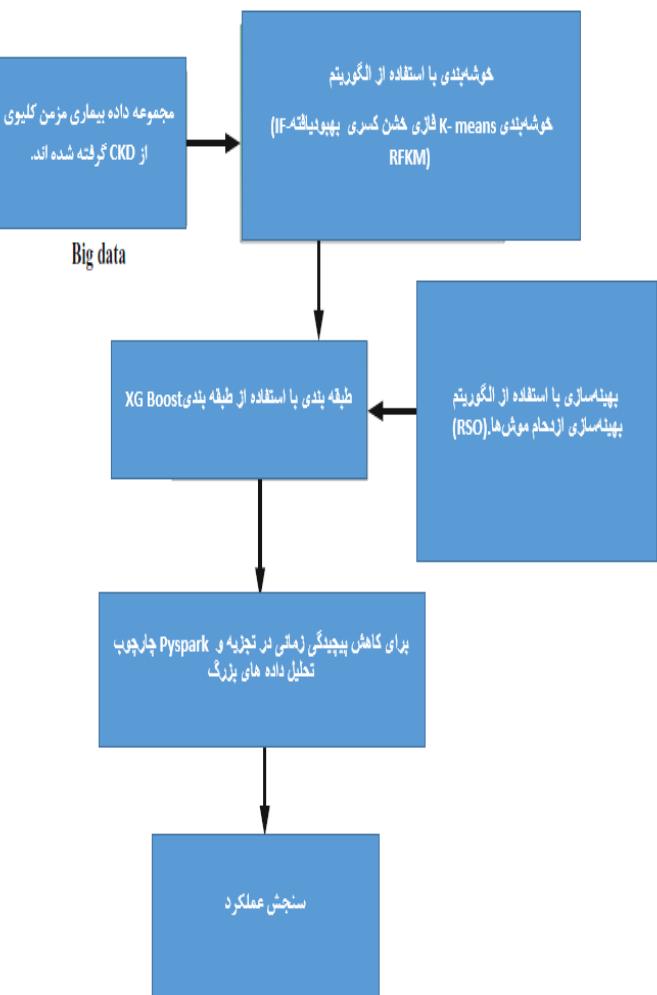
همچنین قوانین انطباق خاصی نتیجه تجزیه و تحلیل پایداری است که سطح لغتش را به عنوان "صفر" همگرا می کند.

$$R = D_a^{1-p} F + \alpha D_x^{-p} F.$$

در فرمول بالا، R تعداد خوش های همپوشانی را نشان می دهد و α نشان دهنده پایداری مثبت، پارامتر F نشان دهنده خطای تخمین \cdot Dx و Da نشان دهنده مرز پایین و بالای خوش است. سپس خطای تخمین به صورت معادله محاسبه می شود.

$$F = b(\vartheta/v) - b_c.$$

بلوک دیاگرام الگوریتم پیشنهادی:





شکل ۲ فلوچارت برای الگوریتم بهینه سازی ازدحام موش برای بهینه سازی افزایش حرکت شدید

سپس بهترین نقطه تقسیم تخمین زده می شود. پس از آن، مقادیر وزن خاصی را برای هر گره برگ جدید تعیین کنید. در نهایت، گره های با سود منفی با فرآیند هرس حذف می شوند. اجازه میدهیم مجموعه ویژگی U_i شامل بردارهای ویژگی U_1, U_2, \dots, U_m , $here, i = 1, 2, \dots, m$ امتیاز اهمیت ویژگی را تخمین بزنید بر اساس اینکه هر ویژگی چند بار برای توزیع داده های آموزشی به صورت مورب در کل درختان استفاده می شود. نمره اهمیت ویژگی به صورت معادله داده می شود.

طبقه‌بندی کلمه واقعی موافقه هستند انتخاب می‌شود. تقریباً ۱۰ برابر سریع‌تر از روش‌های موجود در یک پلتفرم است. انعطاف پذیری ارائه شده توسط XGBoost بسیار زیاد است و با یک سایت خاص ادغام نشده است، بنابراین، طبقه‌بندی CKD با کمک XGBoost ممکن است مستقل از پلتفرم باشد، این یک مزبت قابل توجه است. منظم سازی یک ویژگی حیاتی الگوریتم XGBoost است، زیرا به جلوگیری از مشکلات بیش از حد داده ها کمک می‌کند. تکنیک تقویت گرادیان شدید (XG boost) یکی از کارآمدترین روش های مقیاس پذیر مدل‌های یادگیری ماشینی با استراتژی تقویت درخت است.

تقویت XG با استفاده از مجموعه ای از چندین درخت تصمیم ساخته شده است که به طور موثر مشکل اضافه برآش را در طول طبقه‌بندی حل می‌کند. در ابتدا، یک درخت تصمیم با چندین گره برگ ساخته می‌شود. هر گره یک ویژگی واحد را تعریف می‌کند که برای انجام طبقه‌بندی ضروری است.

پیچیدگی و جلوگیری از مشکل بیش از حد برآش در طول طبقه بندي توسط معادله ارائه شده است.

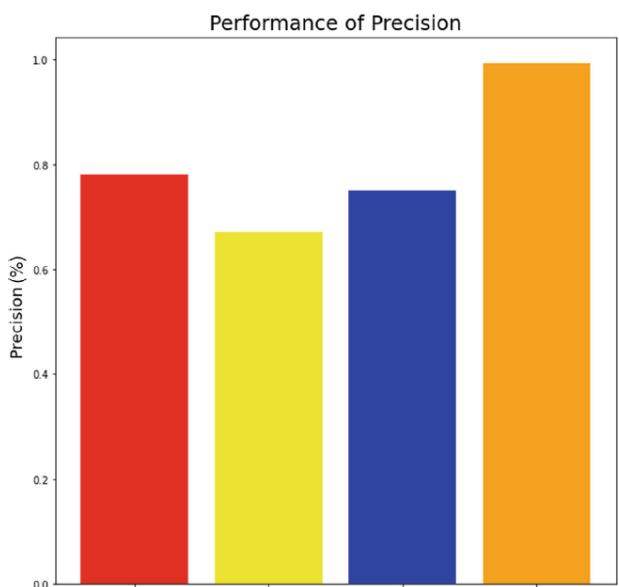
$$\Omega = \Psi^W + \frac{1}{2} \lambda \sum_{j=1}^W T_{j^2},$$

در جایی که پارامتر تعداد برگ‌ها را در درخت تصمیم نشان می‌دهد، پارامتر T_{j^2} امتیاز روی برگ j را نشان می‌دهد، خروجی نشان‌دهنده تابع تلفات محاسبه قابل تشخیص است که تفاوت را در میان پیش‌بینی اندازه‌گیری می‌کند، و Ψ دلالت بر دنباله‌ای پیوسته از یک سری زمانی دارد. بنابراین، تابع هدف "Z" مدل تقویتی XG پیشنهادی در معادله بیان شده است.

$$Z = K + \Omega.$$

در طبقه‌بندي‌کننده تقویت XG، میانگین و انحراف استاندارد به عنوان نزول گرادیان برای بهینه‌سازی تابع هدف استفاده می‌شود. مدل تقویت XG در معادله زیر بیان شده است.

$$Z(W) = \sum_{i=1}^n \left[h_i q_w(A_i) + \frac{1}{2} g_i q_w^2(A_i) \right] + \Omega(q_w),$$



شکل ۴ عملکرد صحت

در اینجا پارامتر A_i نشان‌دهنده بردار ویژگی در نقطه داده است و پارامتر n تعداد تکرارهای انجام شده برای دستیابی به حداقلر عمق را نشان می‌دهد. تابع هدف تقویت XG به عنوان معادله تعریف می‌شود.

$$F_{obj}(\theta) = K(\theta) + \Omega(\theta),$$

$$K(\theta) = k(\hat{b}_i, b_i), \Omega(\theta) = \mathfrak{I} + \frac{1}{2} \lambda \|T\|^2,$$

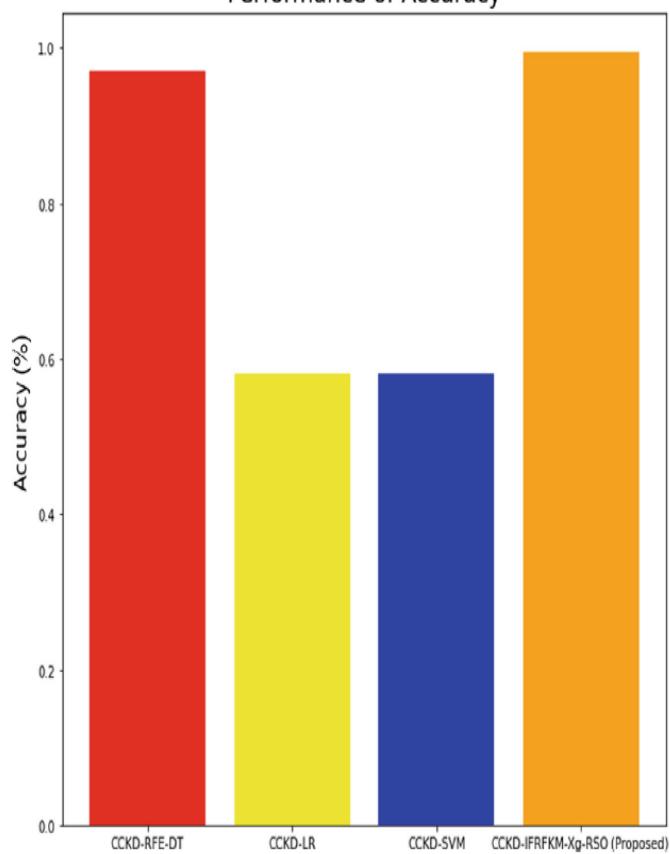
$$IR_i = \{A | A = T_i U_i\}.$$

در اینجا پارامتر T_i مقدار وزن را برای هر ویژگی مشخص می‌کند و پارامتر U_i مجموعه ویژگی‌ها را نشان می‌دهد، خروجی طبقه‌بندي در نقطه داده در معادله بیان می‌شود.

$$B'_i = \sum_{m=1}^m q_i,$$

در اینجا پارامتر تعداد درختان تصمیم را نشان می‌دهد و پارامتر q_i خروجی طبقه‌بندي از درخت تصمیم را نشان می‌دهد. سپس، توابع ضرر برای آموزش مدل تقویت XG برای دستیابی به بهترین نتایج طبقه‌بندي بهینه می‌شود و عملکرد از دست دادن برای طبقه‌بندي کلیه‌ها با کارکرد طبیعی مشخص می‌شود.

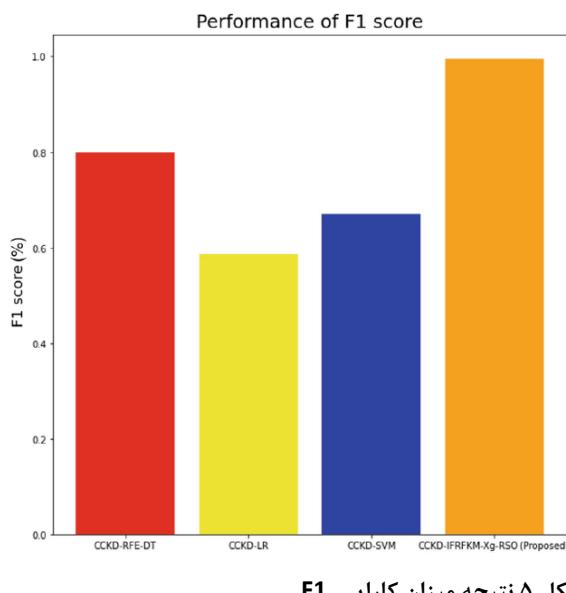
Performance of Accuracy



شکل ۳ عملکرد دقت بیماری در معادله زیر نشان داده شده است

$$K = -\frac{1}{N} \sum_i^N ((B_i \log e_i) + (1 - B_i) \log (1 - e_i)),$$

در جایی که پارامتر K تابع ضرر را نشان می‌دهد که تخمین می‌زنند که مدل طبقه‌بندي پیشنهادی چقدر پیش‌بینی می‌کند، B_i نشان‌دهنده زمان جدی تابع ضرر است. تابع تنظیم برای کنترل



شکل ۵ نتیجه میزان کارایی F1
Save translation

اولین جمعیت موش را به صورت q_i راه اندازی کنید، و برای مقداردهی اولیه جمعیت لانه های میزبان b_i . تا جایی که $i = 1, 2, \dots, m$

$$q = X.q_i(a) + D.(q_s(a) - q_i(a)).$$

اجازه دهید X موقعیت موش ها را مشخص کند، $q_i(a)$ و $q_s(a)$ حد پایین و بالای منطقه جستجو را در بعد امشخص می کند، D عدد تصادفی یکنواخت را در محدوده $[0, 1]$ مشخص می کند.

مرحله ۲: تولید تصادفی

هنگامی که فرآیند مقداردهی اولیه انجام می شود، پارامترهای ورودی به صورت تصادفی ایجاد می شوند. حداکثر مقداری برآزندگی بسته به شرایط دقیق فوق پارامتر تعیین می شود. سپس به صورت تصادفی جمعیت ارزش فرآیند را برای کاهش نرخ خطا ایجاد می کند.

Save translation

مرحله ۳: عملکرد برآزندگی

در این قسمت برای دستیابی به تابع هدف، مانند کاهش نسبت خط، پیچیدگی محاسباتی برای افزایش دقت مزمن ارزیابی می شود همچنین در اینجا، پارامترهای $K(\vartheta)$ و $\Omega(\vartheta)$ با استفاده از RSO بهینه می شوند.

مرحله ۴: جستجوی طعمه(هدف)

در فرمول بالا $K(\vartheta)$ و $\Omega(\vartheta)$ پارامترهای تنظیم شده در طبقه‌بندی کننده تقویت XG هستند، سپس تفاوت بین نرخ پیش‌بینی b_i است، همچنین آن نشان‌دهنده افزایش اطلاعات و XGBoost این ترم ۱۲ افزایش می‌یابد $2 || T$ مرتبط با الگوریتم متعارف GBD، λ پارامتر منظم شده را نشان می‌دهد، T دلالت بر وزن برگها دارد. به حداکثر رساندن آیتم می‌تواند از برآزش جلوگیری کند و توانایی تعمیم مازول را افزایش دهد. خروجی‌های طبقه‌بندی از طبقه‌بندی کننده تقویت XG پیشنهادی تحت مقادیر آستانه مختلف برای به دست آوردن نتایج طبقه‌بندی بهینه آزمایش می‌شوند.

بهینه‌سازی پارامترها با استفاده از الگوریتم بهینه‌سازی ازدحام موش‌ها

بهینه‌سازی ازدحام موش‌ها (RSO) برای تنظیم پارامترهای طبقه‌بندی کننده تقویت XG برای دستیابی به پارامترهای بهینه استفاده می‌شود. این پارامترها برای دستیابی به دقت بیشتر با کاهش نرخ خطا تنظیم می‌شوند. الگوریتم RSO یک الگوریتم فراابتکاری است که از تعادل بهینه در میان مراحل اکتشاف و بهره برداری استفاده می‌کند.

این یک الگوریتم فراابتکاری مبتنی بر جمعیت است. در این مقاله، بهروزرسانی با راهاندازی عوامل جستجو (موش) ایجاد می‌شود و توسط مجموعه‌ای از قوانین در تکرارهای تعیین‌شده ایجاد، حذف، یا اصلاح می‌شود. از آنجایی که به خودی خود پیشرفت کرده است، نسبت به روش تنظیم اضافی، یعنی فاز با جستجوی تصادفی، زمان تکرار کمتری را می‌طلبد، سپس پارامترهای هایپر بهینه را تنظیم می‌کند.

شکل ۲ فلوچارت الگوریتم RSO را برای بهینه‌سازی تقویت XG نشان می‌دهد. فرآیند گام به گام RSO به شرح زیر است:

مرحله ۱: مقداردهی اولیه

شکل ۶ عملکرد و کارایی فراخوان مرحله ۶: خاتمه

فراپارامتر بهینه $(\varphi) \Omega$ و $K(\varphi)$ در تقویت XG با استفاده از RSO انتخاب می‌شوند که می‌تواند مرحله ۳ را به طور مکرر تکرار کند تا زمانی که معیارهای توقف برآورده شود. در نهایت، طبقه‌بندی‌کننده تقویت XG بهترین طبقه‌بندی بیماری مزمن کلیوی بهینه پویا را پیدا می‌کند تا با کاهش پیچیدگی محاسباتی با استفاده از رویکرد RSO، دقت را افزایش دهد.

۴- نتیجه و بحث

در این مقاله، پیش‌بینی و طبقه‌بندی بیماری‌های مزمن کلیوی مبتنی بر داده‌های بزرگ Hadoop با استفاده از بهینه‌ساز ازدحام موش‌های صحرایی IF-RFKM و XGboost ارائه شده است. Scikit-learn روش پیشنهادی در پایتون با استفاده از Keras، OpenCV library on Intel Xeon NVIDIA GeForce RAM فعال شد. یک کارت گرافیک GTX 1080 Ti همچنین عملکرد روش پیشنهادی با روش‌های CCKD-MKC-۳۱،۲۳ CCKD-LR، CCKD-RFE-DT موجود CKD SVM مقایسه شده است. همچنین داده‌ها از مجموعه داده همچنین آزمایش تولید می‌شوند. که در آن ۱۲۴۸۰۰ داده گرفته شده است. از این تعداد ۸۰ درصد برای فرآیند آموزش و ۲۰ درصد برای فرآیند تست استفاده می‌شود.

عملکرد اندازه‌گیری

معیارهای کاربردی و عملکرد، دقت، اندازه، صحت، امتیاز F1، میزان خطای تحلیل به شکل زیر تحلیل می‌شوند.

رفتار حرکت موش‌ها در طول جست و جو به صورت ریاضی با استفاده از استراتژی به روز رسانی موقعیت در معادله نشان داده شده است.

$$X = S - a \times \left(\frac{S}{Max_{iter}} \right),$$

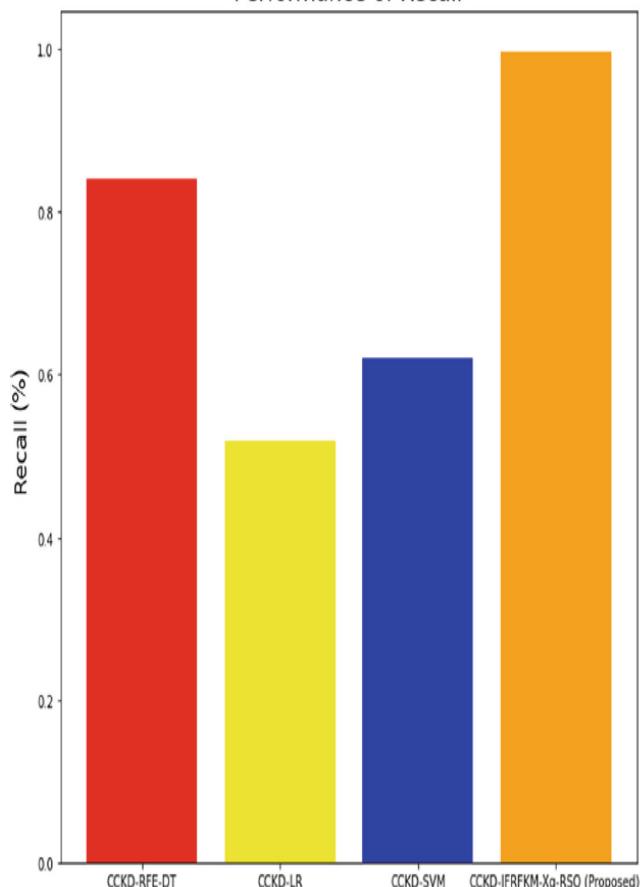
که در آن ...، ۰، ۱، ۲، Maxiter، a= و سپس S عدد تصادفی را نشان می‌دهد. سپس پارامتر X نشان دهنده اکتشاف و بهره برداری بهتر در طول تکرار است.

مرحله ۵: بروزرسانی موقعیت عامل جستجو

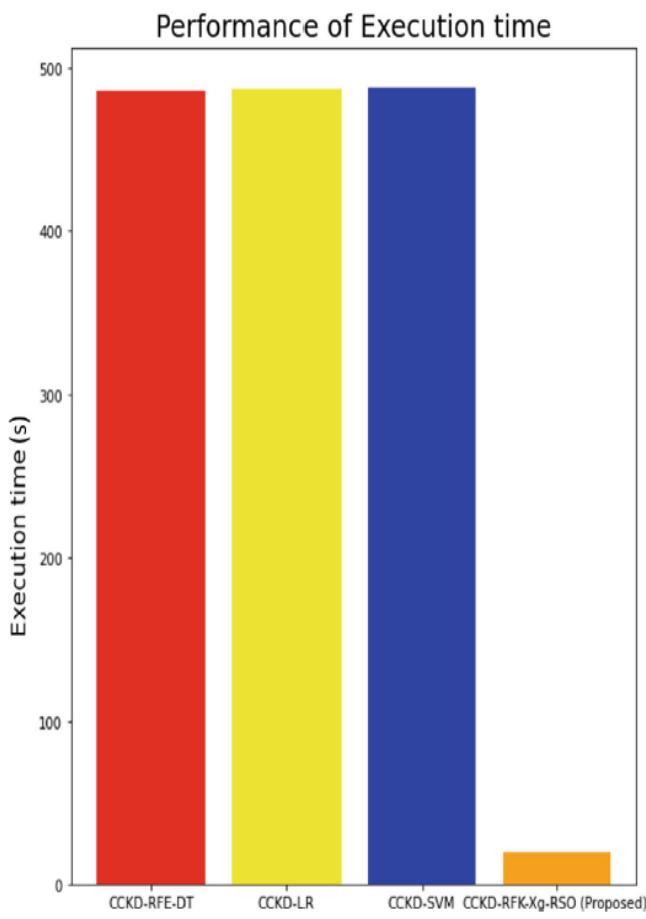
برای ارتقای مکان عوامل جستجو با بکارگیری معادله زیر از آن استفاده می‌کنیم. در قرمول زیر $(a + 1)q_i$ نشان دهنده به روز رسانی موقعیت بعدی است. راه حل بهینه را با ارتقای موقعیت های دیگر عامل جستجو در مورد عامل جستجوی بعدی ذخیره می‌کند. سپس اکتشاف و بهره برداری با تنظیم پارامترهای X و D تضمین می‌شود.

$$q_i(a + 1) = |q_s(a) - q|,$$

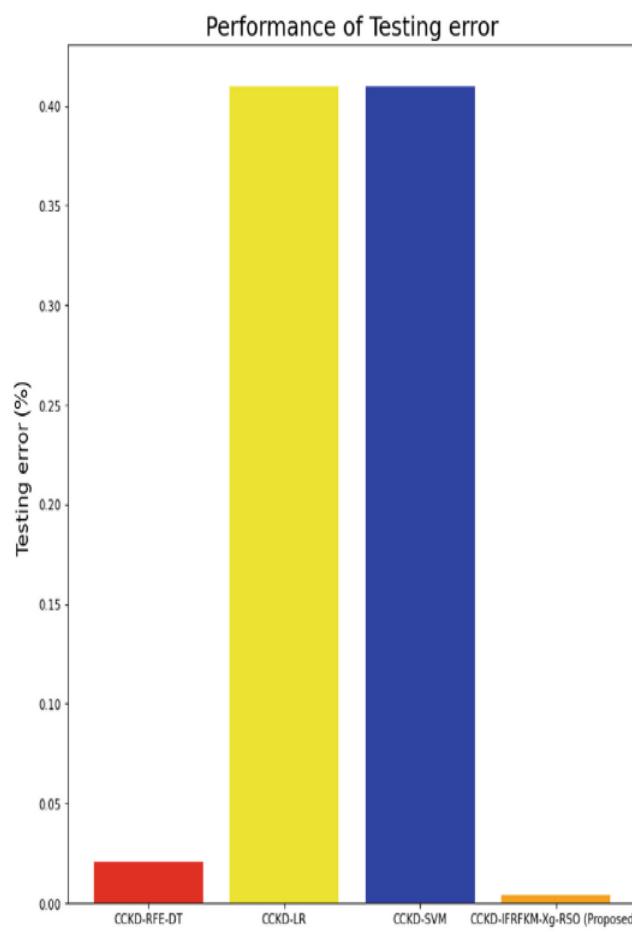
Performance of Recall



$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}.$$



شکل ۸ عملکرد زمان اجرا



شکل ۷ عملکرد میزان خطأ

- مثبت واقعی (TP): نرمال به درستی به نرمال تشخیص داده می شود.

- منفی واقعی (TN): غیر طبیعی به درستی به غیر طبیعی تشخیص داده می شود.

- مثبت کاذب (FP): غیر طبیعی به طور نامناسب به نرمال تشخیص داده می شود.

- منفی کاذب (FN): طبیعی به طور نامناسب به غیر طبیعی تشخیص داده می شود.

محاسبه دقیق

این نسبت پیش‌بینی‌های واقعی را در مقابل تعداد کلی موارد نشان می‌دهد. این با استفاده از معادله زیر به دست می آید

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FNR}}.$$

F1 امتیاز

این مقیاس دقیق با فراخوانی و میانگین هارمونیک دقیق را با فراخوانی نشان می دهد که در معادله زیر بیان می شود.

$$\text{F-measure} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}.$$

تحلیل و مقایسه تحلیل عملکرد کلیه مزمن

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}.$$

محاسبه صحیح

بهترین خطاب اندازه گیری صحیح و درستی است که از طریق فرمول زیر محاسبه می شود.

CCKD-MKC-. CCKD-LR-. CCKD-RFE-DT-. CCKD-MKC-. موجود، مانند SVM مقایسه می شود. در این بیماری مزمن کلیوی، فرآخوانی روش پیشنهادی CCKD-IF-RFKM-Xg-RSO ۱۷.۴۵٪، CCKD-RFE-DT-. CCKD-LR-. و ۱۳.۴۱٪ بیشتر از روش های موجود مانند CCKD-. CCKD-LR-. و CCKD-. را نشان می دهد.

شکل ۷ معیارهای عملکرد نرخ خطای را با روش های مختلف نشان می دهد. در اینجا، میزان خطای پیشنهادی CCKD-IF-RFKM-Xg-RSO اندازه گیری می شود و عملکرد به ترتیب با روش های CCKD-MKC-. CCKD-LR-. CCKD-RFE-DT-. CCKD-MKC-. موجود مانند SVM مقایسه می شود. در این بیماری مزمن کلیوی، میزان خطای روش پیشنهادی CCKD-IF-RFKM-Xg-RSO ۷۵.۰۳٪، CCKD-. و ۳۶.۱۱٪ کمتر از روش های موجود، مانند CCKD-. CCKD-LR-. RFE-DT-. CCKD-MKC-. است.

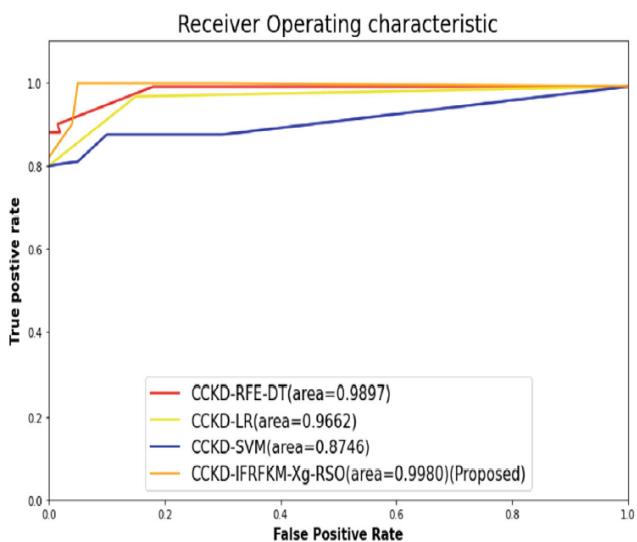
شکل ۸ عملکرد زمان اجرا را با روش های مختلف نشان می دهد. در اینجا، زمان اجرای CCKD-IF-RFKM-Xg-RSO پیشنهادی CCKD- اندازه گیری می شود و عملکرد با روش های موجود، مانند CCKD-MKC-SVM-. CCKD-LR-. RFE-DT-. در این بیماری مزمن کلیوی، زمان اجرای روش پیشنهادی CCKD-IF-RFKM-Xg-RSO ۹۵.۰۳٪، CCKD-LR-. CCKD-RFE-DT-. کمتر از روش های موجود، مانند CCKD-IF-RFKM-Xg-RSO ۹۴.۵۶٪ و ۹۱.۲۲٪. در شکل ۹، ROC پیشنهادی CCKD-IF-RFKM-Xg-RSO در شکل ۹، ROC پیشنهادی CCKD-IF-RFKM-Xg-RSO ۹۶.۰۳٪ و ۹۶.۸۰٪ بیشتر از روش موجود مانند CCKD-MKC-SVM-. CCKD-LR-. CCKD-RFE-DT-. است.

۵- نتیجه گیری

در این مقاله، IF-RFKMIs پیش‌بینی بیماری CKD را پیشنهاد کرد.

این بیماری با استفاده از طبقه‌بندی XGboost برای طبقه‌بندی مراحل بیماری‌های مزمن کلیوی به عنوان نرمال و غیر طبیعی طبقه‌بندی می شود. هچنین RSO برای بهینه سازی پارامترهای طبقه‌بندی کننده XGboost پیشنهاد شده است. در اینجا، داده ها به طور تصادفی از مجموعه داده CKD تولید می شوند. فرآیند شبیه سازی به زبان پایتون اجرا می شود. روش پیشنهادی به دقت بالاتر ۹۵.۶۸٪، ۹۹.۳۲٪ و ۹۱.۱۳٪، امتیاز F بالا ۹۱.۵۷٪، CCKD-RFE موجود می باشد. در مقایسه با CCKD-RFE موجود می رسد.

در شکل ۳ معیارهای عملکرد دقت را با روش های مختلف نشان می دهد. در اینجا، دقت CCKD-IF-RFKM-Xg-RSO های پیشنهادی در نظر گرفته شده و عملکردها به ترتیب با چندین CCKD-. CCKD-LR-. CCKD-RFE-DT-. CCKD-MKC-. و MKC-SVM مقایسه می شوند.



شکل ۹ منحنی ROC برای بیماری مزمن کلیوی بیماری کلیوی، دقت روش پیشنهادی CCKD-IF-RFKM-Xg-RSO ۱.۱۲٪ و ۱۰.۸٪ بالاتر از روش های موجود مانند CCKD-MKC-. CCKD-LR-. CCKD-RFE-DT-. است.

شکل ۴ معیارهای عملکرد دقت را با روش های مختلف نشان می دهد. در اینجا، دقت CCKD-IF-RFKM-Xg-RSO پیشنهادی در نظر گرفته شده و عملکردها به ترتیب با چندین روش قبلی مانند CCKD-MKC-SVM-. CCKD-LR-. CCKD-RFE-DT-. مقایسه می شوند. در این بیماری مزمن کلیوی، دقت روش پیشنهادی CCKD-IF-RFKM-Xg-RSO ۱۱.۰۲٪، CCKD-MKC-. CCKD-LR-. CCKD-RFE-DT-. موجود است.

شکل ۵ معیارهای عملکرد امتیاز F1 را با روش های مختلف نشان می دهد. در اینجا، امتیاز F1 CCKD-IF-RFKM-Xg-RSO پیشنهادی است اندازه گیری و عملکرد به ترتیب با چندین روش موجود مقایسه می شود، مانند CCKD-LR-. CCKD-RFE-DT-. CCKD-MKC-SVM-. در این بیماری مزمن کلیوی، امتیاز F1 CCKD-IF-RFKM-Xg-RSO ۶.۲۵٪ و ۷.۵۵٪ روش پیشنهادی ۱۲.۴۲٪ بیشتر از CCKD-LR-. CCKD-RFE-DT-. وجود است.

شکل ۶ معیارهای عملکرد فرآخوان را با روش های مختلف نشان می دهد. در اینجا، فرآخوان پیشنهادی CCKD-IF-RFKM-Xg-RSO اندازه گیری می شود و عملکرد به ترتیب با روش های RSO

OFDM system by chaotic key generation-based Paillier

cryptography along with LDPC and its side channel estimation using machine learning technique. *J Circuits Syst Comput.* 2022;31(5):2250093.

12. Rajesh P, Shajin FH, Vijaya AN. An efficient estimation model for induction motor using BMO-RBFNN technique. *Process Integr Optim Sustain.* 2021;5(4):777-792.

13. Shajin FH, Rajesh P, Raja MR. An efficient VLSI architecture for fast motion estimation exploiting zero motion pre-judgment technique and a new quadrant-based search algorithm in HEVC. *Circuits Syst Signal Process.* 2022;41(3):1751-1774.

14. Rajesh P, Muthubalaji S, Srinivasan S, Shajin FH. Leveraging a dynamic differential annealed optimization and recalling enhanced recurrent neural network for maximum power point tracking in wind energy conversion system. *Technol Econ Smart Grids Sustain Energy.* 2022;7(1):1-5.

15. Pacheco F, Exposito E, Gineste M, Baudoin C, Aguilar J. Towards the deployment of machine learning solutions in network traffic classification: a systematic survey. *IEEE Commun Surv Tutor.* 2018;21(2):1988-2014.

16. Rhee KE, Kessl S, Lindback S, Littman M, El-Kareh RE. Provider views on childhood obesity management in primary care settings: a mixed methods analysis. *BMC Health Serv Res* 2018;18(1):55.

17. Bhosale AS, Jadhav SS, AhireHS, JaybhayAY, RajeswariK. Study of medicine dispensing machineandhealthmonitoringdevices. In:Gunjan VK,Suganthan PN, Haase J, Kumar A, eds. *Cybernetics, Cognition and Machine Learning Applications.* Springer; 2021:297-305.

18. Din IU, Guizani M, Rodrigues JJ, Hassan S, Korotaev VV. Machine learning in the internet of things: designed techniques for smart cities. *Future Gener Comput Syst.* 2019;100:826-843.

19. Sharma S, SinghG, SharmaM. A comprehensive review and analysis

مراجع

1. Kumar S, Singh M. Big data analytics for healthcare industry: impact, applications, and tools. *Proceedings of the Big Data Mining and Analytics;* 2018:48-57; IEEE.
2. AzeroualO, Saake G, Schallehn E. Analyzing data quality issues in research information systems via data profiling. *Int J InfManag.* 2018;41:50-56.
3. Ahir RK, Chakraborty B. A meta-analytic approach for determining the success factors for energy conservation. *Energy.* 2021;230:120821.
4. Nemati M, Ansary J, Nemati N. Machine-learning approaches inCOVID-19 survival analysis and discharge-time likelihood prediction using clinical data. *Patterns.* 2020;1(5):100074.
5. KhareN,Devan P, Chowdhary CL, et al.SMO-DNN:spider monkey optimization and deep neural network hybrid classifier model for intrusion detection. *Electronics.* 2020;9(4):692.
6. Zhao Y, Zhang C, Zhang Y,Wang Z, Li J. A review of data mining technologies in building energy systems: load prediction, pattern identification, fault detection and diagnosis. *Energy Built Environ.* 2020;1(2):149-164.
7. Javaid M, Khan IH. Internet of things (IoT) enabled healthcare helps to take the challenges of COVID-19 pandemic. *J Oral Biol Craniofacial Res.* 2021;11(2):209-214.
8. NadimMI, Alam J, Khanam H. Heart disease prediction using data mining approach; 2019.
9. Sornalakshmi M, Balamurali S, Venkatesulu M, et al. Hybrid method for mining rules based on enhanced Apriori algorithm with sequential minimal optimization in healthcare industry. *Neural Comput Appl.* 2020;31:1-4.
10. Wang J, Zhan Q. Visualization analysis of artificial intelligence Technology in Higher Education Based on SSCI and SCI journals from 2009 to 2019. *Int J Emerg Technol Learn.* 2021;16(8):20-23.
11. Shajin FH, Rajesh P. FPGA realization of a reversible data hiding scheme for 5G MIMO-

Downloaded from https://iranpaper.ir
https://www.tarjomano.com
https://www.tarjomano.com

- VIJAYALAKSHMI AND RAMARAJ **15 of 15**
29. Khamparia A, Saini G, Pandey B, Tiwari S, Gupta D, Khanna A. KDSAE: chronic kidney disease classification with multimedia data learning using deep stacked autoencoder network. *Multimed Tools Appl.* 2020;79(47):35425-35440.
30. JongboOA, AdetunmbiAO, OgunrindeRB, Badeji-Ajisafe B. Development of an ensemble approach to chronic kidney disease diagnosis. *Scientific African.* 2020;8:e00456.
31. Nusinovici S, Tham YC, Yan MY, et al. Logistic regression was as good as machine learning for predicting major chronic diseases. *J Clin Epidemiol.*
32. Vijayalakshmi J, Ramaraj E. A Hadoop-big data analytic model to predict and classify chronic kidney diseases using improved fractional rough fuzzy K-means clustering and extreme gradient boost rat swarm optimizer. *Concurrency Computat Pract Exper.* 2022;34(28):e7354. doi: 10.1002/cpe.7354

- of supervised-learning and soft computing techniques for stress diagnosis inhumans. *Comput Biol Med.* 2021;134:104450.
20. Zhang T, Ma F, Yue D, Peng C, O'Hare GM. Interval type-2 fuzzy local enhancement based rough k-means clustering considering imbalanced clusters. *IEEE Trans Fuzzy Syst.* 2019;28(9):1925-1939.
21. Alsharman N, Alzyoud F, Saaidah A, Almomani O. Machine learning and answer set program rules towards traffic light management. *IJATCSE.* 2020;9(3):2535-2541.
22. Dhiman G, Garg M, Nagar A, Kumar V, Dehghani M. A novel algorithm for global optimization: rat swarm optimizer. *J Ambient Intell Humaniz Comput.* 2021;12(8):8457-8482.
23. Chaudhuri AK, Sinha D, Banerjee DK, Das A. A novel enhanced decision treemodel for detecting chronic kidney disease. *Netw Model Anal Health Inform Bioinform.* 2021;10(1):1-22.
24. JerlinRubini L, Perumal E. Efficient classification of chronic kidney disease by using multi-kernel support vector machine and fruit fly optimization algorithm. *Int J Imaging Syst Technol.* 2020;30(3):660-673.
25. Nithya A, Appathurai A, Venkatadri N, RamjiDR, PalaganCA. Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images. *Measurement.* 2020;149:106952.
26. Pradeepa P, Jeyakumar MK. An efficient self-tuning spectral clustering algorithm for chronic kidney disease prediction. *Mater Today.* 2020.
27. Akben SB. Early stage chronic kidney disease diagnosis by applying data mining methods to urinalysis, blood analysis and disease history. *IRBM.* 2018;39(5):353-358.
28. Aldhyani TH, Alshebami AS, Alzahrani MY. Soft clustering for enhancing the diagnosis of chronic diseases over machine learning algorithms. *J Healthc Eng.* 2020;2020:1-16.