

طراحی و پیاده‌سازی سیستم تصمیم یار بالینی برای تشخیص و پیش‌بینی بیماری نارسایی مزمن کلیه

محمدرضا افراش^۱ (Ph.D Candidate)، علی ولی‌نژادی^۲ (Ph.D)، مرتضی امرائی^۳ (Ph.D)، رئوف نوپور^۴ (M.Sc)، ناهید محرابی^۵ (Ph.D)، سارا محمدی^۶ (M.Sc)، مصطفی شنبه‌زاده^۷ (Ph.D)

۱- کمیته تحقیقات دانشجویی، دانشکده پیراپزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران

۲- گروه فناوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی سمنان، سمنان، ایران

۳- گروه فناوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی لرستان، خرم‌آباد، ایران

۴- گروه فناوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران

۵- گروه فناوری اطلاعات سلامت، دانشکده علوم پزشکی ارتش جمهوری اسلامی ایران، تهران، ایران

۶- گروه اتاق عمل، دانشکده پیراپزشکی، دانشگاه علوم پزشکی ایلام، ایلام، ایران

۷- گروه فناوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی ایلام، ایلام، ایران

تاریخ دریافت: ۱۴۰۰/۵/۱۴ تاریخ پذیرش: ۱۴۰۰/۹/۷

Mostafa.shanbezadeh@gmail.com

* نویسنده مسئول، تلفن: ۰۹۳۰۰۸۳۳۶۹۱

چکیده

هدف: بیماری نارسایی مزمن کلیه (Chronic kidney disease, CKD) یکی از مهم‌ترین نگرانی‌های سلامت عموم در سراسر جهان است. افزایش مداوم تعداد بیماران مبتلا به مرحله نهایی نارسایی کلیه (End stage renal disease, ESRD) که برای زنده ماندن نیاز به پیوند کلیه و صرف هزینه‌های زیادی دارند، اهمیت تشخیص زودرس و درمان به موقع بیماری را برجسته‌تر کرده است. هدف از مطالعه حاضر طراحی یک سیستم تصمیم یار بالینی برای تشخیص CKD و سپس پیش‌بینی مرحله پیشرفته بیماری برای مدیریت و درمان بهتر بیماران می‌باشد.

مواد و روش‌ها: در این مطالعه گذشته‌نگر- توسعه‌ای، مدارک بالینی ۶۰۰ بیمار مشکوک به CKD با ۲۲ متغیر که طی سال‌های ۱۳۹۸ و ۱۳۹۹ به بیمارستان شهید لبافی‌نژاد تهران مراجعه کرده بودند، مورد بررسی قرار گرفت. بر اساس متغیرهای استخراجی، الگوریتم‌های داده کاوی مانند بیزین ساده، جنگل تصادفی، درخت تصمیم J-48 و شبکه عصبی پرسپترون چندلایه ایجاد شدند. سپس عملکرد مدل‌های طراحی شده بر اساس معیارهای ارزیابی عملکرد الگوریتم‌های طبقه‌بندی‌کننده و روش K-Fold cross validation مورد مقایسه قرار گرفت. در نهایت مناسب‌ترین مدل پیش‌بینی‌کننده بر اساس مقایسه نتایج حاصل از ارزیابی عملکرد الگوریتم‌ها و با به کارگیری زبان برنامه‌نویسی #C پیاده‌سازی گردید.

یافته‌ها: الگوریتم طبقه‌بندی جنگل تصادفی با میزان صحت ۰/۹۹/۸٪ و اختصاصیت ۰/۱۰۰٪ و حساسیت ۰/۹۳/۸٪، ضریب اف ۰/۹۹/۸٪ و ۰/۸۸/۷٪، میزان کاپا ۰/۹۹/۴٪ و ۰/۸۲/۷۳٪ و سطح زیر نمودار (ROC) ۱۰۰٪ و ۰/۹۰/۵۲٪ به عنوان بهترین مدل داده کاوی به ترتیب برای تشخیص و پیش‌بینی CKD شناسایی شد.

نتیجه‌گیری: در مجموع سیستم MC-DMK توسعه یافته بر اساس الگوریتم جنگل تصادفی می‌تواند در محیط‌های واقعی بالینی به صورت کاربردی مورد استفاده قرار گیرد.

واژه‌های کلیدی: نارسایی مزمن کلیه، میزان تصفیه گلومرولی، سیستم تصمیم یار بالینی، داده کاوی، شبکه‌های عصبی کامپیوتری، الگوریتم

مقدمه

بیماری نارسایی مزمن کلیه (Chronic kidney disease: CKD) یکی از مهم‌ترین نگرانی‌های سلامت عمومی در سراسر جهان است [۲،۱]. CKD یک اصطلاح کلی برای اختلالاتی است که بر اساس میزان صدمه کلیه یا میزان تصفیه گلومرولی (gfr<60ml/min per 1.73m²) در بازه زمانی سه ماه و بدون در نظر گرفتن علت بیماری تعریف می‌شود. بنیاد کلیه و بیماری‌های کلیوی امریکا (The American Kidney Foundation: AKF) بر پایه میزان تصفیه گلومرولی (gfr) بیماری مزمن کلیه را به پنج مرحله طبقه‌بندی می‌کند که از

بیماری نارسایی مزمن کلیه (Chronic kidney disease: CKD) یکی از مهم‌ترین نگرانی‌های سلامت عمومی در سراسر جهان است [۲،۱]. CKD یک اصطلاح کلی برای اختلالاتی است که بر اساس میزان صدمه کلیه یا میزان تصفیه گلومرولی

[۳۰،۲۹]. استفاده از این تکنیک‌ها در قالب سیستم‌های تصمیم یار بالین به منظور طبقه‌بندی و پیش‌آگهی ابتلاء و پیش‌بینی خطرات پیشرفت بیماری و مرگ و میرهای ناشی از CKD در مراحل اولیه؛ شناسایی سریع، اولویت‌بندی بیماران و ارائه راه‌کارهای درمانی سفارشی و مبتنی بر نیاز بیمار در مراحل بعدی ضروری است [۳۰-۳۲]. تاکنون سیستم‌های CDSS متعددی در زمینه مدیریت درمان بیماری‌های مزمن ایجاد شده است که در این سیستم‌ها از تکنیک‌های داده کاوی برای تشخیص و پیش‌بینی بیماری‌هایی مانند دیابت، سرطان، بیماری‌های قلبی - عروقی و کلیوی استفاده کرده‌اند [۳۳-۳۶]. این در حالی است که سیستم‌های CDSS طراحی شده برای مدیریت بیماری‌های کلیوی عموماً به تشخیص وجود یا عدم وجود بیماری پرداخته‌اند و بر اساس دانش ما تاکنون پژوهش‌های اندکی برای پیش‌بینی خطر ابتلاء به CKD و پیش‌آگهی پیشرفت بیماری انجام شده است [۲۳،۲۶،۳۷]. به طور مثال در پژوهش Sobrinho (2020) یک سیستم کامپیوتری کمک‌کننده تشخیص (Computer Aided Diagnosis: CAD) مبتنی بر الگوریتم‌های داده کاوی برای طبقه‌بندی بیماران CKD در دو گروه سالم و بیمار طراحی شد [۳۸]. از طرفی Khoong و همکاران (۲۰۱۹) یک سیستم تصمیم یار بالین برای ارائه توصیه در خصوص شناسایی موارد مبتلاء و مدیریت CKD طراحی و پیاده‌سازی کردند [۳۹]. Pesce و همکاران (۲۰۱۵) در پژوهش خود یک سیستم پیش‌بینی‌کننده برای پیش‌آگهی خطر ابتلاء بیماران نروپاتی ایمنونوگلوبولین آ (IgA nephropathy) به مرحله نهایی و پیشرفته نارسایی کلیه (End Stage Renal Disease: ESRD) در دو فاز تعیین وضعیت ESRD و پیش‌بینی زمان ابتلاء به ESRD در بین بیماران Iga پیشنهاد دادند [۴۰]. به علاوه در بسیاری از مطالعات از داده‌های قدیمی و عمومی بر روی تعداد محدودی از الگوریتم‌های داده کاوی استفاده گردیده و به طوری که عملکرد مدل‌های پیاده‌سازی در مواردی ضعیف گزارش شده است [۴۱]. به علت وجود چنین خلاء‌هایی، در پژوهش حاضر تعداد بیش‌تری از تکنیک‌های داده کاوی پیاده‌سازی و بر اساس معیارهای مختلف مورد ارزیابی قرار گرفت. در نهایت بهترین مدل داده کاوی برای تشخیص CKD در مرحله اول، شناسایی شد. سپس برنامه نرم‌افزار MC-DMK تحت ویندوز با زبان برنامه‌نویسی C# به منظور تعیین مرحله بیماری در CKD و ارائه اقداماتی جهت کنترل و مدیریت بیماری بر اساس مرحله تشخیص داده شده برای هر بیمار، پیاده‌سازی شد.

مرحله یک که نشان‌دهنده‌ی آسیب کلیه با نرخ gfr نرمال شروع می‌شود و به مرحله آخر یعنی نارسایی شدید کلیه خاتمه می‌یابد [۴،۳]. در این مرحله کل یا نزدیک به کل عملکرد کلیه از دست می‌رود و بسیاری از بیماران برای زنده ماندن نیاز به پیوند کلیه یا دیالیز هستند [۵،۶]. طبق آمارها شیوع CKD در حدود ۱۰٪ از کل جمعیت سراسر جهان است و این میزان به سرعت در حال افزایش است [۷]. متأسفانه این افزایش در کشورهای در حال توسعه از جمله ایران چشمگیرتر است به طوری که بر طبق پژوهش‌های مختلف میزان شیوع CKD حدود ۶ تا ۱۷٪ است [۸-۱۱].

با توجه به تأثیرات این بیماری در کاهش میزان امید به زندگی، بار اقتصادی زیادی که به فرد، خانواده و جامعه تحمیل می‌کند و در نهایت آمار بالای مرگ و میر ناشی از آن، شناسایی بیماران در معرض خطر، تشخیص اولیه بیماری و اتخاذ تصمیم‌های بالینی در مراحل بعدی توسط تیم درمانی برای پیشگیری از پیشرفت بیماری و مدیریت درمان، بسیار ضروری است [۱۲-۲۱]. متأسفانه به دلیل ضعف برخی از پزشکان در اتخاذ تصمیم‌های دقیق در خصوص شناسایی صحیح بیماری، تعیین شدت و پیش‌بینی رفتار آن، بنابراین نیاز به وجود فناوری‌هایی که بتواند آن‌ها را در تشخیص و پیش‌آگهی به موقع و سفارشی بیماری و کم کردن خطاها کمک کند به شدت حس می‌شود [۲۲-۲۵]. سیستم‌های یادگیری ماشین (Machine Learning) ابزارهایی هستند که با استفاده از اطلاعات و دانش پزشکی به همراه استفاده از قابلیت‌های داده کاوی (Data Mining) به صورت کشف دانش و شناسایی خودکار الگوهای نهفته در داده‌ها، به پیش‌بینی و تشخیص بیماری‌های گوناگون و تجویز توصیه‌های پزشکی برای کمک به ارائه‌دهندگان مراقبتی اقدام می‌کنند [۲۲،۲۶].

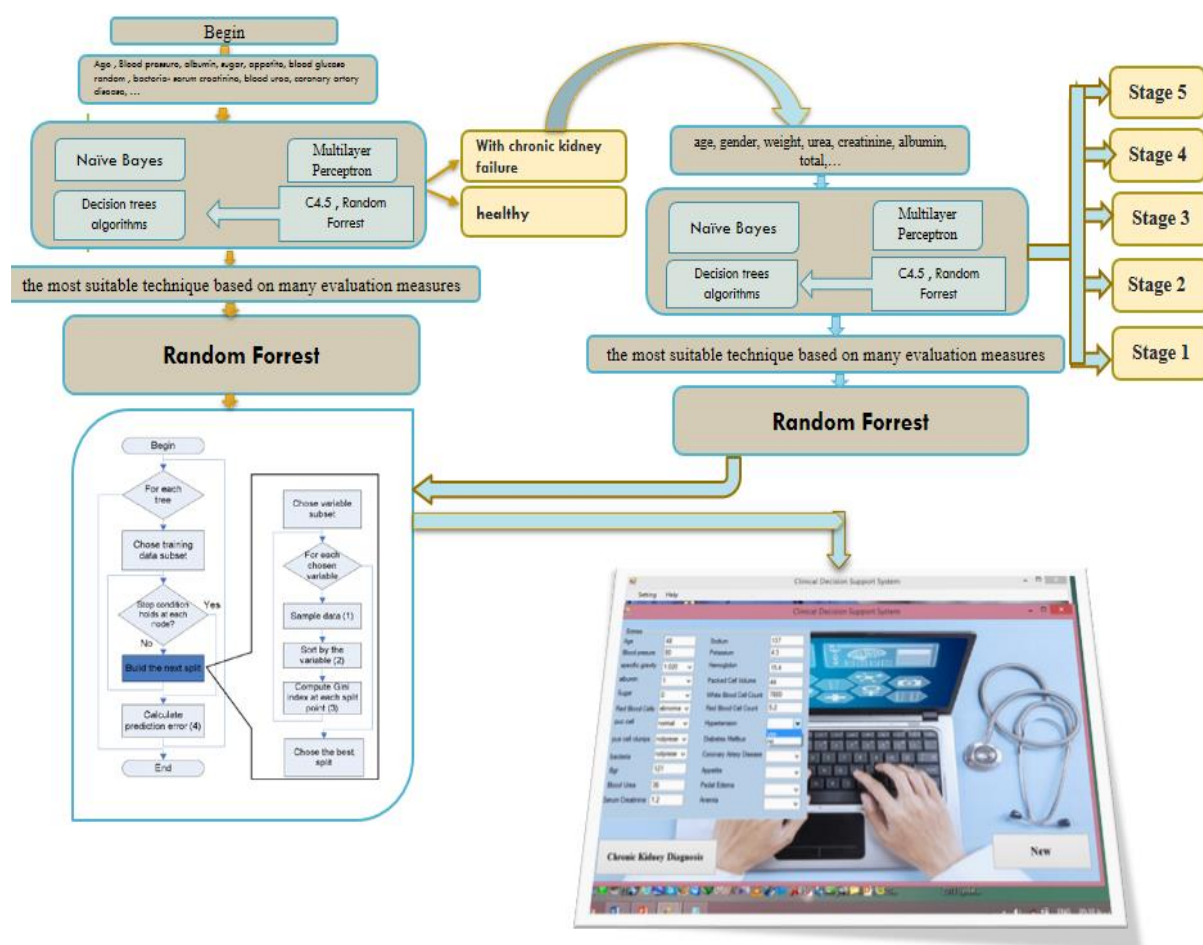
الگوریتم‌های داده کاوی در مجموع به شش طبقه اصلی شامل ۱- دسته‌بندی، ۲- خوشه‌بندی، ۳- کشف قوانین انجمنی، ۴- کشف الگوهای متوالی، ۵- رگرسیون و ۶- تشخیص انحراف تقسیم‌بندی می‌شوند. الگوریتم‌های دسته‌بندی به دو گروه تحت نظارت و بدون نظارت طبقه‌بندی می‌شوند. در روش تحت نظارت هدف تعیین برچسب کلاس یک نمونه جدید از طریق کلاس‌های دارای برچسب گذشته به واسطه طبقه‌بندی داده‌ها به دو قسمت اصلی آموزش و آزمایش است. این در حالی است که در مدل بدون نظارت یادگیری به واسطه خوشه‌بندی و بر روی داده‌های بدون برچسب انجام می‌شود [۲۷،۲۸]. تکنیک‌های داده‌کاوی از ابزارهای محبوب و کاربردی برای محققان و متخصصین بهداشتی به منظور پیش‌بینی و تشخیص بیماری‌ها با استفاده از یک مجموعه داده بالینی است

پایه‌سازی‌های انجام شده بر روی داده و الگوریتم‌های داده کاوی (پیش‌پردازش، آموزش، تست و ارزیابی عملکرد تکنیک‌های داده کاوی) در این مطالعه در محیط برنامه‌نویسی متلبو WEKA انجام شد و نرم‌افزار سیستم تصمیم یار بالینی با استفاده از زبان برنامه‌نویسی C# پایه‌سازی شد.

پرونده بیماران کلیدی سرپایی و بستری شده در بخش اورولوژی بیمارستان شهید لباغی‌نژاد و کلینیک پیوند و دیالیز کلیه شهید رجایی از ۱۳۹۸/۸/۱ تا ۱۳۹۹/۴/۵ مورد بررسی قرار گرفت و داده‌های بالینی و آزمایشگاهی بیماران ضمن توجه به اصول محرمانگی و حفظ حریم شخصی استخراج گردید. در ادامه با استفاده از نظرات متخصصین نفرولوژی، از بین ۵۳ نشانگر بالینی اولیه شناسایی شده، ۲۲ متغیر انتخاب و مقادیر متناسب آن‌ها برای همه افراد استخراج و ثبت گردید. به منظور بهبود کیفیت پایگاه داده در این مرحله از پیش‌پردازش داده‌ها و روش حذف رکوردهای دارای از دست رفتگی بالای اطلاعاتی و موارد خارج از محدوده طبیعی استفاده شد.

مواد و روش‌ها

مطالعه حاضر از نوع توسعه‌ای و به‌صورت گذشته‌نگر، برای تشخیص بیماری CKD در فاز اول و سپس پیش‌بینی مرحله و میزان پیشرفت بیماری در فاز دوم انجام شد. نتایج به‌کارگیری الگوریتم‌های مختلف داده کاوی بر اساس متغیرهای انتخاب شده مورد مقایسه قرار گرفت. از معیارهای مختلف ارزیابی الگوریتم‌های طبقه‌بندی‌کننده برای انتخاب بهترین مدل استفاده شد و سپس سیستم تصمیم یار بالینی بر اساس مدل داده کاوی انتخاب شده و با به‌کارگیری زبان برنامه‌نویسی C# توسعه داده شد. رویکرد کلی سیستم توسعه‌یافته شامل پنج مرحله اصلی به ترتیب: ۱- جمع‌آوری مجموعه داده و پیش‌پردازش داده‌ها، ۳- پایه‌سازی مدل‌های مختلف داده کاوی، ۴- به‌کارگیری معیارهای مختلف ارزیابی مدل‌های پایه‌سازی شده و ۵- توسعه و پایه‌سازی سیستم تصمیم یار بالینی است. رویکرد کلی، پیشنهادی برای توسعه سیستم تشخیص CKD و پیش‌بینی میزان پیشرفت بیماری در شکل ۱ نشان داده شده است. تمام



شکل ۱. رویکرد کلی توسعه سیستم تصمیم یار بالینی تشخیص و پیش‌آگهی CKD

$$f = 2 \frac{\text{precision} * \text{sensitivity}}{\text{precision} + \text{sensitivity}} \quad \text{فرمول (۵)}$$

$$\text{Accuracy} = \frac{\text{true positive}}{\text{true positive} + \text{false positive}} \quad \text{فرمول (۶)}$$

بعد از انتخاب بهترین مدل طبقه‌بندی در دو فاز تشخیص بیماری نارسایی مزمن کلیه و پیش‌بینی مرحله آن، سیستم تصمیم یار بالینی در محیط برنامه‌نویسی C# طراحی و پیاده‌سازی گردید.

پروتکل انجام این پژوهش به لحاظ اخلاقی با کد پروتکل (IR.MEDILAM.REC.1399.0220) به تأیید کمیته اخلاق در پژوهش دانشگاه علوم پزشکی ایلام رسیده است.

نتایج

در این پژوهش پرونده بالینی مربوط به ۶۳۵ مورد مشکوک به اختلالات کلیوی که طی سال‌های ۱۳۹۸ و ۱۳۹۹ به بیمارستان شهید لبافی‌نژاد و کلینیک پیوند و دیالیز کلیه شهید رجایی شهر تهران مراجعه کرده بودند، مورد بررسی قرار گرفت. تعداد ۳۵ رکورد اطلاعاتی که بیش از ۷۰٪ از دست رفتگی داده داشت از مطالعه حذف گردید. از مجموع ۶۰۰ رکورد باقی‌مانده، ۴۰۰ بیمار مبتلا به CKD و ۲۰۰ فرد سالم بود. اطلاعات موارد با توجه به ۲۲ متغیر بالینی شامل ۹ ویژگی عددی و ۱۳ ویژگی اسمی استخراج و به عنوان ورودی مدل‌های داده کاوی مورد استفاده قرار گرفتند. این متغیرها عبارت بودند از: سن، جنس، میزان فشار خون، وضعیت حاملگی، سطح قند خون، شمارش گلبول‌های قرمز خون، شمارش گلبول‌های سفید خون، کم‌خونی، ادم اندام‌های انتهایی، میزان اشتها، بیماری‌های عروق کرونری، دیابت، میزان سدیم، میزان پتاسیم، سطح هموگلوبین، میزان نیتروژن اوره خون، کراتینین سرم، مصرف نمک، حجم مجموعه سلول‌های متراکم، وجود باکتری / میکروارگانیسم در خون (عفونت خون)، عفونت ادراری و میزان ورزش / فعالیت بدنی.

بر روی مجموعه داده انتخاب شده، ۴ الگوریتم مختلف داده کاوی شامل روش‌های درخت تصمیم از جمله الگوریتم 48z و جنگل تصادفی با در نظر داشتن ۲۲ ویژگی به عنوان ورودی سیستم در بستر نرم‌افزار Weka و الگوریتم شبکه عصبی مصنوعی و بیزین ساده در محیط نرم‌افزار متلب اجرا شد. مقادیر مختلف k در روش K-Fold cross validation تست و مورد مقایسه قرار گرفت و k=۱۰ که در آن ۹۰٪ مجموعه داده برای آزمایش و ۱۰٪ برای تست الگوریتم‌ها انتخاب گردید. شکل‌های ۲ تا ۵، نتایج 10-Fold cross validation را برای ۴ الگوریتم پیاده‌سازی شده بر اساس ۲۲ متغیر انتخاب شده برای تشخیص بیماری CKD نشان می‌دهد.

در نهایت برای پر کردن فیلدهای خالی داده‌های کمی از میانگین عددی ستون‌های مربوط به هر کدام از متغیرهای اطلاعاتی و داده‌های کیفی از روش کای نزدیک‌ترین همسایه (KNN) استفاده شد.

به منظور طراحی سیستم تصمیم یار بالینی برای تشخیص بیماری CKD و پیش‌بینی میزان پیشرفت بیماری از چندین روش داده کاوی شامل الگوریتم شبکه عصبی مصنوعی (Artificial Neural Network) الگوریتم درخت تصمیم‌گیری 48-z، مدل جنگل تصادفی (Random Forest) و ساده بیزین (Naïve Bayes) استفاده شد. لازم به ذکر است که تمامی متغیرهایی مورد استفاده برای فاز یک سیستم تصمیم یار بالینی (تشخیص بیماری CKD) به عنوان ورودی سیستم، در فاز دوم مطالعه نیز (یعنی پیش‌بینی میزان پیشرفت CKD) نیز مورد استفاده قرار گرفت.

به منظور مقایسه نتایج حاصل از پیاده‌سازی الگوریتم‌های مختلف به‌کار گرفته شده، از روش 10-fold cross validation و هفت معیار ارزیابی عملکرد تکنیک‌های داده کاوی شامل ویژگی (specificity)، حساسیت (sensitivity)، دقت (precision)، صحت (accuracy)، معیار کاپا (kappa)، سطح زیر نمودار (Roc) و ضریب اف (F-measure) استفاده شد. در روش اعتبارسنجی K-Fold cross validation، مجموعه داده به k بخش مساوی تقسیم می‌شود که از این تعداد، k-1 بخش مجموعه داده برای آموزش الگوریتم‌های داده کاوی و بخش باقی‌مانده به منظور تست الگوریتم‌ها در هر مرحله استفاده می‌شود. در ادامه معیارهای ارزیابی عملکرد الگوریتم‌ها تعریف شده است.

ویژگی: عبارت است از توانایی سیستم برای تشخیص سالم بودن افرادی که در واقع سالم هستند (فرمول ۲) [۴۲].
حساسیت: عبارت است از توانایی سیستم برای تشخیص بیمار بودن افرادی که در واقع بیمار هستند (فرمول ۳) [۴۳].

$$\text{Sensitivity} = \frac{\text{True Positive}}{\text{True Positive} + \text{False negative}}$$

کوهن کاپا: در مطالعاتی که بیش از دو دسته‌بندی‌کننده برای تخمین وجود دارد، شاخص kappa میزان توافق بین این دو تخمین زنده را به دست می‌آورد (فرمول ۴). در این فرمول pr (a) میزان توافق و pr (e) برابر با میزان شانس توافق است. در شرایطی که مقدار محاسبه شده برای کاپا به ۱ نزدیک شود، میزان توافق بین دسته‌بندی‌کننده بیش‌تر است [۴۳].

$$\text{kappa} = \frac{\text{pr}(a) - \text{pr}(e)}{1 - \text{pr}(e)} \quad \text{فرمول (۴)}$$

دو معیار ارزیابانه دیگر شامل ضریب اف و صحت بر اساس فرمول‌های ۵ و ۶ محاسبه می‌شوند [۴۳].

```

Time taken to build model: 0 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      386          96.5 %
Incorrectly Classified Instances    14           3.5 %
Kappa statistic                    0.9261
Mean absolute error                0.038
Root mean squared error            0.1853
Relative absolute error             8.111 %
Root relative squared error        38.267 %
Total Number of Instances          400

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
                0.956   0.02    0.988     0.956   0.972     0.98     ckd
                0.98    0.044   0.93      0.98    0.955     0.98     notckd
Weighted Avg.   0.965   0.029   0.966     0.965   0.965     0.98

=== Confusion Matrix ===
  a  b  <-- classified as
239 11 | a = ckd
  3 147 | b = notckd

```

شکل ۲. پیاده سازی مدل درخت تصمیم 48 در بستر Weka

```

Time taken to build model: 0.01 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      380          95 %
Incorrectly Classified Instances    20           5 %
Kappa statistic                    0.8961
Mean absolute error                0.0479
Root mean squared error            0.2046
Relative absolute error            10.2125 %
Root relative squared error        42.2526 %
Total Number of Instances          400

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
                0.92     0        1          0.92   0.958     1        ckd
                1       0.08    0.882     1      0.938     1        notckd
Weighted Avg.   0.95   0.03    0.956     0.95   0.951     1

=== Confusion Matrix ===
  a  b  <-- classified as
230 20 | a = ckd
  0 150 | b = notckd

```

شکل ۳. پیاده سازی مدل جنگل تصادفی در بستر Weka

```

Time taken to build model: 0.4 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      399          99.75 %
Incorrectly Classified Instances    1           0.25 %
Kappa statistic                    0.9947
Mean absolute error                0.041
Root mean squared error            0.084
Relative absolute error             8.7441 %
Root relative squared error        17.3414 %
Total Number of Instances          400

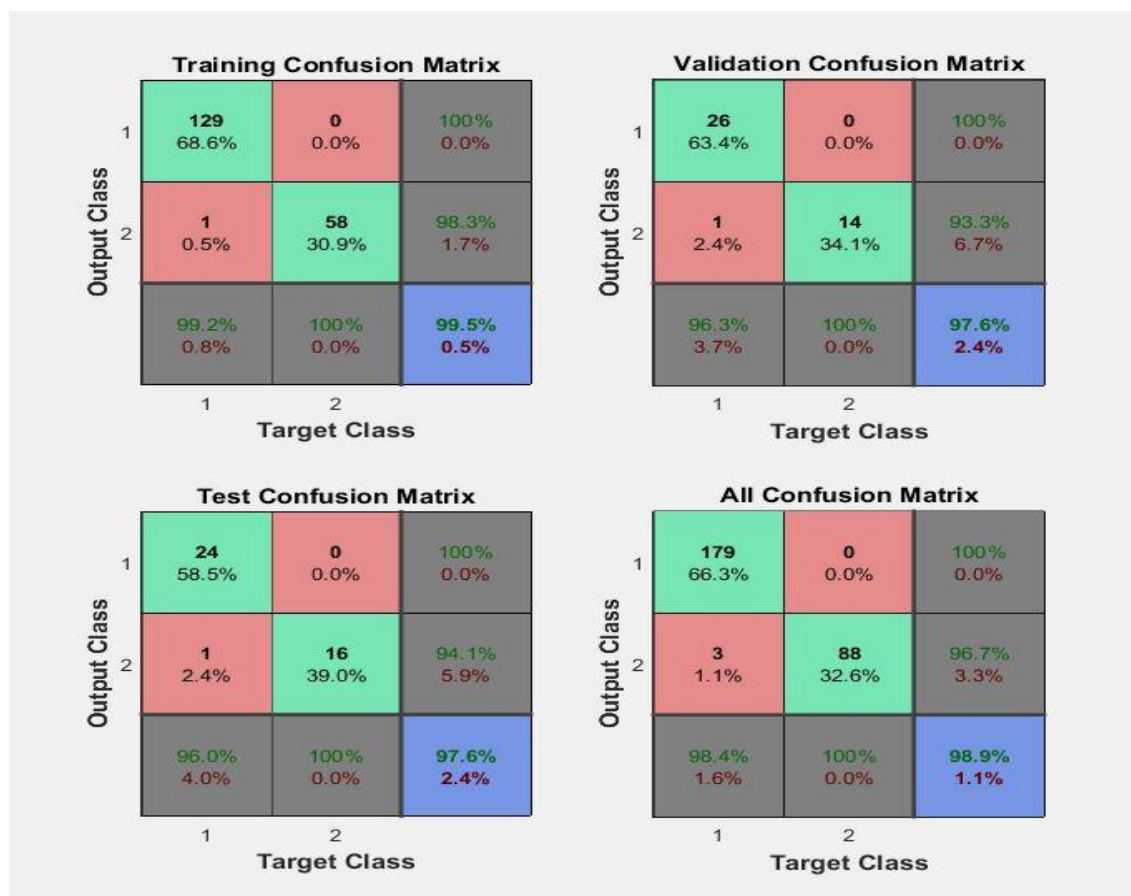
=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
                0.996   0        1          0.996   0.998     1        ckd
                1       0.004   0.993     1      0.997     1        notckd
Weighted Avg.   0.998   0.002   0.998     0.998   0.998     1

=== Confusion Matrix ===
  a  b  <-- classified as
249  1 | a = ckd
  0 150 | b = notckd

```

شکل ۴. پیاده سازی مدل ساده بییزی در بستر Weka



شکل ۵. ماترس آشفته‌گی نتایج آموزش و آزمایش داده‌ها در شبکه‌ی عصبی مصنوعی

چندلایه استاندارد (MLP) با یک لایه میانی، تعداد ۲۲ نورون برای ورودی، ۱۵ نورون برای لایه میانی و ۲ خروجی در محیط برنامه‌نویسی برای تشخیص وجود یا عدم وجود CKD نیز در تصویر ۵ ارایه شده است. نتایج آموزش و تست داده‌ها به منظور پیش‌بینی CKD در پژوهش حاضر در شکل ۵ نشان داده شده است.

نتایج حاصل از پیاده‌سازی مدل شبکه عصبی مصنوعی نشان می‌دهد که ۹۸/۴٪ از داده‌ها به درستی و ۱/۴٪ از افراد نادرست طبقه‌بندی شده‌اند. نتایج کلی حاصل از پیاده‌سازی مدل‌های منتخب در مطالعه حاضر برای تشخیص CKD به منظور مقایسه و انتخاب بهترین مدل در شکل ۶ نشان داده شده است.

نتایج کلی حاصل از پیاده‌سازی مدل‌های منتخب در مطالعه حاضر برای پیش‌بینی CKD به منظور مقایسه و انتخاب بهترین مدل در شکل ۷ نمایش داده شده است. لازم به ذکر است که تمامی متغیرهایی مورد استفاده برای فاز یک سیستم تصمیم یار بالینی (تشخیص) به عنوان ورودی سیستم، در فاز دوم (پیش‌بینی) نیز مورد استفاده قرار گرفتند.

با توجه به نتایج حاصل از ارزیابی مدل‌های پیاده‌سازی شده بر اساس معیارهای مختلف ارزیابی عملکرد الگوریتم‌ها،

همان‌طور که در شکل ۲ نشان داده شده است، حدود ۹۶/۵٪ از داده‌ها توسط الگوریتم 48-زبه درستی و حدود ۳/۵٪ از داده‌ها توسط این مدل به اشتباه طبقه‌بندی شده است. میانگین وزنی عملکرد مدل بر اساس میزان کاپا، حساسیت، ویژگی، دقت، ضریب اف و سطح ROC به ترتیب به ترتیب ۰/۹۲٪، ۹۶/۵٪، ۹۸٪، ۹۶/۶٪، ۹۶/۵٪ و ۹۸٪ به دست آمد. نتایج حاکی از عملکرد بهینه این مدل در طبقه‌بندی موارد CKD بود.

بر اساس نتایج حاصل از شکل ۳، در مدل جنگل تصادفی ۹۹/۷۵٪ از داده‌ها به درستی طبقه‌بندی شده است و حدود ۲/۲۵٪ خطای طبقه‌بندی گزارش شده است. میانگین وزنی عملکرد مدل بر اساس میزان کاپا ۹۹/۴۷٪، دقت ۹۹/۸٪، حساسیت ۹۹/۷۵٪، ویژگی ۱۰۰٪، ضریب اف ۹۹/۸٪ و شاخص ROC برابر با ۱ بود. به علاوه نتایج حاصل از پیاده‌سازی تکنیک بیزین در محیط Weka نشان داد که ۹۵٪ از داده‌ها توسط این مدل به درستی طبقه‌بندی و چیزی در حدود ۵٪ از موارد توسط مدل نادرست طبقه‌بندی گردید (شکل ۴).


تحلیل نتایج حاصل از تصویر ۴ نشان داد که مدل ساده بیزی دارای میزان ۸۹/۶٪ برای شاخص اندازه‌گیری کاپا، مقدار ۱۰۰٪ برای حساسیت و مقدار ۱ برای معیار ROC می‌باشد. نتایج حاصل از پیاده‌سازی شبکه‌ی عصبی مصنوعی پرسپترون

در این مطالعه راه‌کارهای بالینی برای مدیریت CKD بر اساس مرحله بیماری و مداخلات پیشنهادی (gfr rate) در جدول ۱ نمایش داده شده است.


AKF بر پایه میزان تصفیه گلوبولین سطحی CKD را به پنج مرحله طبقه‌بندی می‌کند. مقدار طبیعی gfr در افراد سالم بین ۹۰-۱۲۰ mL/min/1.73 m² می‌باشد. هم‌چنین مقدار gfr کم‌تر از ۶۰ (mL/min/1.73 m²) در یک بازه‌ی زمانی بیش‌تر از ۳ ماه نشان‌دهنده بیماری مزمن کلیه و مقدار gfr کم‌تر از ۱۵ (mL/min/1.73 m²) نمایانگر نارسایی کامل کلیه است که بیمار در این مرحله برای زنده ماندن نیاز به دیالیز یا پیوند کلیه دارد [۴۵،۴۴].

الگوریتم جنگل تصادفی با میزان صحت ۹۹/۸٪ و ۸۸/۶۶٪، اختصاصیت ۱۰۰٪ و ۹۳/۸٪، حساسیت ۹۹/۷۵٪ و ۸۸/۷٪، ضریب اف ۹۹/۸٪ و ۸۸/۷٪، میزان کاپا ۹۹/۴٪ و ۸۲/۷۳٪ و سطوح زیر نمودار ۱۰۰٪ و ۹۰/۵۲٪ به ترتیب برای تشخیص و پیش‌بینی CKD به عنوان کارآمدترین مدل انتخاب شد.


بعد از انتخاب بهترین مدل طبقه‌بندی‌کننده در دو فاز تشخیص بیماری نارسایی مزمن کلیه و پیش‌بینی مرحله آن، سیستم تصمیم‌یار بالینی پیشنهادی در محیط برنامه‌نویسی C# و در بستر توسعه‌ای Weka و بر اساس بهترین مدل انتخاب شده طراحی و پیاده‌سازی گردید (شکل ۸).



شکل ۶. نتایج حاصل از پیاده‌سازی فنون داده‌کاوی مختلف برای تشخیص CKD



شکل ۷. نتایج حاصل از پیاده‌سازی فنون داده‌کاوی مختلف برای پیش‌بینی CKD



شکل ۸. رابط کاربری سیستم تصمیم یار بالینی MC-DMK برای تشخیص و پیش‌آگهی CKD

جدول ۱. اقدامات و مداخلات بالینی برای مدیریت CKD در سطوح مختلف بیماری

درجه	توصیف	میزان gfr	راهکارها و مداخلات
۰	در معرض خطر	بالاتر از ۹۰	غربالگری- اصلاح سبک زندگی- درمان مشکلات طبی همزمان-
۱	آسیب کلیوی- بیماری خفیف	از ۶۰ تا ۸۹	تشخیص و درمان- کند کردن سیر پیشرفت- کاهش خطر عوارض قلبی و عروقی
۲	بیماری متوسط	۳۰ تا ۵۹	ارزیابیو درمان عوارض
۳	بیماری شدید	۱۵ تا ۲۹	آمادگی بیمار برای درمان جایگزین
۴	نارسایی کلیه	کمتر از ۱۵	انجام دیالیز و پیوند کلیه

در پیش‌بینی بیماری از راهنماها، استانداردهای طلایی و متون پزشکی معتبر و زیر نظر متخصصین نفرولوژی انجام شده است، بنابراین می‌توان ادعا نمود که ۲۲ متغیر ورودی برای آموزش مدل‌های داده کاوی برای تشخیص و پیش‌آگهی دقیق CKD بهینه‌سازی شده است.

در این مطالعه یک سیستم هوشمند مبتنی بر تکنیک‌های داده کاوی با نام MC-DMK برای تشخیص، مدیریت و پیش‌بینی خطر ابتلاء به CKD بر اساس تکنیک‌های داده کاوی ارائه شد. به منظور توسعه سیستم، روش‌های مختلف داده کاوی در دو مرحله شامل تشخیص CKD و پیش‌بینی میزان پیشرفت CKD پیاده‌سازی و عملکرد هر یک برای تعیین بهترین مدل مورد مقایسه قرار گرفت.

تکنیک‌های مورد استفاده در پژوهش حاضر شامل روش‌های شبکه‌های عصبی مصنوعی، درخت تصمیم‌گیری [۱۰]، جنگل تصادفی و الگوریتم ساده بی‌زین بود که از طریق تعداد ۲۲ متغیر منتخب بالینی و آزمایشگاهی مربوط به ۴۰۰ بیمار مبتلا به CKD و ۲۰۰ فرد سالم طراحی و پیاده‌سازی شدند.

در فاز ارزیابی معیارهای مختلف ارزیابانه برای کمی‌سازی عملکردی الگوریتم‌های منتخب به منظور انتخاب کاراترین مدل

بحث و نتیجه‌گیری

از آنجایی که شدت علائم و وخامت ناخوشی در بیماران مبتلاء به CKD در قالب مراحل پنجگانه بیماری بسیار متغیر است، بنابراین ارائه مدل‌هایی جهت حمایت از تصمیم و پیش‌بینی احتمال بدحال شدن بیماران با استفاده از تکنیک‌های یادگیری ماشین به منظور سطح‌بندی بیماران، حمایت از تصمیمات بالینی و انتخاب بهترین مداخله درمانی و حمایتی حیاتی است [۳۷، ۴۶]. تشخیص زودرس CKD به درمان به موقع بیماران مبتلاء و همچنین جلوگیری از رسیدن بیماران به مراحل نهایی و پیشرفته نارسایی کلیه کمک‌کننده است. توسعه سیستم‌های تصمیم یار بالینی بر اساس رویکردهای مختلف یادگیری ماشین و انتخاب بهترین مدل می‌تواند منجر به پیروی بهتر از دستورالعمل‌های درمانی و پیش‌بینی و تشخیص زود هنگام بیماری شود [۲۶، ۳۷].

در پژوهش حاضر پس از شناسایی و اولویت‌بندی مهم‌ترین متغیرهای بالینی و استفاده از آن‌ها به عنوان ورودی به مدل‌های داده کاوی، سپس به مقایسه کارایی و عملکرد روش‌های مختلف داده کاوی در دو فاز تشخیص و پیش‌بینی CKD پرداخته شد. در این مطالعه از آنجایی که استخراج فاکتورها و عوامل موثر

الگوریتم جنگل تصادفی با میزان دقت ۸۵/۷۰٪، بازخوانی ۸۵٪/۶۰٪، ضریب اف ۸۵/۵۰٪ و سطح ROC ۹۰٪/۴۰٪ در مقایسه با سایر الگوریتم‌ها عملکرد بهتری در پیش‌بینی پیشرفت بیماری CKD داشت [۲۹]. مشابهاً در پژوهش دیگر توسط Senan (۲۰۲۱) الگوریتم جنگل تصادفی با میزان صحت، دقت، بازخوانی و ضریب اف ۱۰۰٪ به عنوان بهترین مدل در تشخیص و طبقه‌بندی CKD گزارش شد [۵۲]. به طور مشابه در مطالعه Almahfuz (۲۰۲۱) الگوریتم داده کاوی جنگل تصادفی با صحت طبقه‌بندی ۹۹٪ به عنوان موثرترین الگوریتم برای شناسایی و پیش‌بینی موثر CKD معرفی شد [۳۸]. نتایج مطالعه Al-Hyari و سایرین (۲۰۱۳) نشان داد که الگوریتم درخت تصمیم‌گیری با میزان دقت ۹۲/۲٪، بالاترین عملکرد را در بین دیگر الگوریتم‌های دسته‌بندی کسب کرد [۵۳].

از تحلیل نتایج مطالعات گذشته می‌توان به برتری الگوریتم‌های مختلف شبکه عصبی مصنوعی (MLP, CNN, DNN) و درخت تصمیم (J48, C4.5, Random forest) در تشخیص و پیش‌بینی CKD رسید. این نتایج با پژوهش حاضر هماهنگی دارند. در پژوهش حاضر با توجه به نتایج به دست آمده از ارزیابی عملکرد الگوریتم‌های منتخب، الگوریتم جنگل تصادفی با میزان صحت ۹۹/۸٪ و ۸۸/۶۶٪، اختصاصیت ۱۰۰٪ و ۹۳/۸٪، حساسیت ۹۹/۷۵٪ و ۸۸/۷٪، ضریب اف ۹۹/۸٪ و ۸۸/۷٪، میزان کاپا ۹۹/۴٪ و ۸۲/۷۳٪ و سطوح زیر نمودار ۱۰۰٪ و ۹۰/۵۲٪ به ترتیب برای تشخیص و پیش‌بینی CKD دارای بالاترین عملکرد بود.

با این وجود اجرای پژوهش حاضر دارای برخی محدودیت‌ها بود. مهم‌ترین محدودیت‌های پژوهش حاضر، گذشته‌نگر بودن رکوردهای اطلاعاتی و وجود برخی فیله‌های اطلاعاتی خالی، غیریکپارچه، ناقص، دارای خطا و موارد غیرطبیعی بود که می‌توانست در فرآیند مدل‌سازی تأثیر منفی داشته باشد. از دیگر محدودیت‌ها، استفاده از چهار روش داده کاوی و نیز عدم استفاده از داده‌های تصویربرداری در مجموعه داده انتخابی به منظور تشخیص و پیش‌بینی CKD بود. محدود بودن مراکز استخراج داده یکی دیگر از نارسایی‌هایی بود که بر کیفیت مدل‌سازی، جامعیت و تعمیم‌پذیری داده‌ها تأثیر منفی گذاشت. بنابراین پیشنهاد می‌گردد به منظور بهبود کیفیت مدل و کاهش بیش‌دآوری در پیش‌بینی، پژوهش‌های بیش‌تری پس از انجام اعتبارسنجی‌های دقیق‌تر، با استفاده از الگوریتم‌های داده کاوی متنوع‌تر در پایگاه‌های داده بزرگ‌تر، با در نظر داشتن متغیرهای تشخیصی بیش‌تر و با کیفیت‌تر، برگرفته از چند مرکز

مورد محاسبه و مقایسه قرار گرفت. با توجه به نتایج به دست‌آمده از ارزیابی تکنیک‌های داده کاوی، الگوریتم جنگل تصادفی بهترین عملکرد را کسب کرد. در این الگوریتم رسیدن به حساسیت ۹۹/۷۵٪ در تشخیص CKD و حساسیت ۸۸/۷٪ در پیش‌بینی میزان پیشرفت CKD از طریق الگوریتم جنگل تصادفی بدین معنا بود که تقریباً نزدیک به تمامی موارد CKD در مرحله نخست و ۸۸٪ از آن‌ها در مرحله دو متوسط سیستم به درستی تشخیص و پیش‌بینی داده شده است. هم‌چنین نتایج به دست‌آمده برای ویژگی و دیگر پارامترهای ارزیابانه نرخ بالای را گزارش کردند. بنابراین سیستم پیشنهادی با عنوان MC-DMK می‌تواند در عمل و به عنوان یک سیستم تصمیم‌یار بالینی کاربردی مورد استفاده قرار گیرد.

تاکنون مطالعات گوناگونی در خصوص مقایسه تکنیک‌های هوشمندسازی و یادگیری ماشین به منظور طراحی سیستم‌های تصمیم‌یار بالین بهینه و کارآمد برای تشخیص CKD و در مرحله پیشرفته‌تر پیش‌بینی رفتار این بیماری و پیش‌آگهی عوارض آن انجام شده است. پژوهش Roy (۲۰۲۱) به مقایسه تکنیک‌های منتخب داده کاوی به منظور شناسایی CKD پرداخت. در نهایت الگوریتم درخت تصمیم با صحت طبقه‌بندی ۹۹٪/۳۶٪ بهترین عملکرد را به دست آورد [۴۷]. در مطالعه Darveshwala (۲۰۲۱) با هدف مقایسه عملکرد الگوریتم‌های داده کاوی گوناگون، مدل شبکه عصبی عمیق (DNN) با صحت ۹۹٪ بالاترین عملکرد را در طبقه‌بندی موارد CKD کسب کرد [۴۸]. شبکه عصبی کانولوشن (CNN) در پژوهش Krishnamurthy (۲۰۲۱) با میزان ROC برابر با ۰/۹۵۷ بالاترین عملکرد را در پیش‌بینی CKD به دست آورد [۴۶]. مشابهاً در مطالعه Almansur (۲۰۱۹) الگوریتم شبکه عصبی MLP با صحت طبقه‌بندی ۹۹/۷۵٪ بهترین کارایی را در پیش‌بینی CKD داشت [۴۹]. پژوهش Sobrinho (۲۰۲۰) به منظور مقایسه عملکرد الگوریتم‌های داده کاوی منتخب با هدف تشخیص CKD انجام پذیرفت، در نهایت درخت تصمیم J-48 با صحت طبقه‌بندی ۹۵٪ بالاترین عملکرد را به دست آورد [۵۰]. Abdulah و همکاران (۲۰۱۹) پس از مقایسه الگوریتم‌های یادگیری ماشین متعدد برای طبقه‌بندی CKD به این نتیجه رسیدند که الگوریتم جنگل تصادفی با میزان صحت، حساسیت، اختصاصیت و سطح زیر نمودار (AUC) به ترتیب ۹۸٪/۸۲۵، ۹۸٪/۰۴، ۱۰۰٪ و ۹۸/۹٪ بالاترین عملکرد را داشت [۵۱]. الگوریتم درخت تصمیم C4.5 در مطالعه Boukenze (۲۰۱۶) با میزان دقت ۹۸٪، بازخوانی (Recall) ۹۹٪ و ضریب اف ۹۹٪ به عنوان کارآمدترین مدل برای پیش‌بینی CKD معرفی شد [۳۰]. در مطالعه Afhami (۲۰۱۸)

منابع

- [1] Assari S. Racial disparities in chronic kidney diseases in the United States; a pressing public health challenge with social, behavioral and medical causes. *J Nephropharmacol* 2016; 5: 4-6.
<https://doi.org/10.1007/s40615-016-0239-7>
PMid:27270925
- [2] Formica RN Jr., Gill JS. Should the United States employ free market practices to solve the hidden public health crisis of chronic kidney disease? *Am J Transplant* 2020; 20: 1217-1218.
<https://doi.org/10.1111/ajt.15718>
PMid:31746545
- [3] Goraya N, Simoni J, Jo CH, Wesson DE. Treatment of metabolic acidosis in patients with stage 3 chronic kidney disease with fruits and vegetables or oral bicarbonate reduces urine angiotensinogen and preserves glomerular filtration rate. *Kidney Int* 2014; 86: 1031-1038.
<https://doi.org/10.1038/ki.2014.83>
PMid:24694986
- [4] Tuganbekova S, Gaipov A, Turebekov Z, Saparbayev S, Shaimardanova G, Popova N, et al. Fetal renal stem cell transplant in nephrotic and nonnephrotic glomerulonephritis with stage 2-4 chronic kidney disease: potential effect on proteinuria and glomerular filtration rate. *Exp Clin Transplant* 2015; 13: 156-159.
- [5] Lee YB, Han K, Kim B, Jun JE, Lee SE, Ahn J, et al. Risk of end-stage renal disease from chronic kidney disease defined by decreased glomerular filtration rate in type 1 diabetes: A comparison with type 2 diabetes and the effect of metabolic syndrome. *Diabetes Metab Res Rev* 2019; 35: e3197.
<https://doi.org/10.1002/dmrr.3197>
- [6] Roshanaei G, Omid T, Faradmal J, Safari M, Poorolajal J. Determining affected factors on survival of kidney transplant in living donor patients using a random survival forest. *Koomesh* 2018; 20: 517-523. (Persian).
- [7] van Haalen H, Jackson J, Spinowitz B, Milligan G, Moon R. Impact of chronic kidney disease and anemia on health-related quality of life and work productivity: analysis of multinational real-world data. *BMC Nephrol* 2020; 21: 88.
<https://doi.org/10.1186/s12882-020-01746-4>
PMid:32143582 PMCid:PMC7060645
- [8] Tabrizi R, Zolala F, Nasirian M, Baneshi MR, Etmiran A, Sekhavati E, et al. Estimation of the prevalence of chronic kidney disease: The results of a model based estimation in Kerman, Iran. *Med J Islamic Repub Iran* 2016; 30: 338. (Persian).
- [9] Keshmiri YS, Mirzaie SK, Sali S, Yadegarynia D, Abolghasemi S, Tehrani S, et al. Evaluation of symptoms, radiological findings, laboratory data and outcome in COVID-19 patients with chronic kidney disease at Tehran, Iran. 2020. (Persian).
<https://doi.org/10.21203/rs.3.rs-101128/v1>
- [10] Hosseinpanah F, Kasraei F, Nassiri AA, Azizi F. High prevalence of chronic kidney disease in Iran: a large population-based study. *BMC Public Health* 2009; 9: 44.
<https://doi.org/10.1186/1471-2458-9-44>
PMid:19183493 PMCid:PMC2658666
- [11] Sharifian Dorche M, Esfandiari N, Rahdar M. Correlation between anteroposterior renal pelvic diameter and vesicoureteral reflux in congenital hydronephros. *Koomesh* 2021; 23: 227-232. (Persian).
<https://doi.org/10.52547/koomesh.23.2.227>
- [12] Kafle K, Balasubramanya S, Horbuluk T. Prevalence of chronic kidney disease in Sri Lanka: a profile of affected districts reliant on groundwater. *Sci Total Environment* 2019; 694: 133767.
<https://doi.org/10.1016/j.scitotenv.2019.133767>
PMid:31756806
- [13] Aghlmand S, Rahimi B, Farrokh-Eslamlou H, Nabilou B, Yusefzadeh H. Determinants of Iran's bilateral intra-industry trade in pharmaceutical industry. *Iran J Pharm Res* 2018; 17: 822. (Persian).
- [14] Shabaninejad H, Yusefzadeh H, Mehralian G, Rahimi B. The structure of the world pharmaceutical market:

مراقبتی، و با توجه به ماهیت آینده‌نگر بودن جمع‌آوری داده‌ها، انجام پذیرد.

در مطالعه حاضر عملکرد الگوریتم‌های منتخب داده کاوی بر روی داده‌های بالینی بیماران مبتلاء به CKD و موارد سالم مدل‌سازی و از طریق معیارهای هفتگانه ارزیابانه مقایسه شدند. پس از انجام انتخاب ویژگی و شناسایی متغیرهای پیش‌بینی‌کننده مهم (۲۲ متغیر) و پیاده‌سازی مدل‌های طبقه‌بندی، در نهایت الگوریتم جنگل تصادفی بهترین عملکرد را کسب کرد. استفاده از الگوریتم‌های داده کاوی و به طور خاص جنگل تصادفی در شناسایی موثر بیماران CKD، پیش‌بینی رفتار و عوارض بیماری و سطح‌بندی بیماران نقش بسزایی در حفظ هزینه اثربخشی درمان، اولویت‌بندی صحیح منابع و بهبود ایمنی و کیفیت مراقبتی خواهد داشت.

مدل‌های پیاده‌سازی شده در مطالعه حاضر علاوه بر تشخیص خودکار CKD، قابلیت پیش‌بینی مرحله بیماری و ارائه راهکار برای مدیریت این بیماری به عنوان بخشی از نوآوری‌های این مطالعه را دارا هستند. به علاوه سیستم پیشنهادی دارای پتانسیل بالایی در طبقه‌بندی موارد بیمار و سالم و پیش‌بینی رفتار بیماری در آینده و سطح‌بندی موارد به صورت صحیح و دقیق را داراست. این قابلیت‌ها احتمالاً باعث خواهد شد تا MC-DMK طراحی شده در این پژوهش به صورت سفارشی و کاربردی برای محیط‌های بالینی قابل استفاده باشد.

تشکر و قدردانی

مقاله حاضر برگرفته از یک طرح پژوهشی مصوب در دانشگاه علوم پزشکی ایلام با کد IR.MEDILAM.REC.1399.0220 می‌باشد. از مسئولین معاونت تحقیقات این دانشگاه و هم‌چنین بیمارستان لبافی‌نژاد شهر تهران که در انجام این پژوهش تیم تحقیق را یاری رساندند، کمال تشکر و قدردانی را داریم.

مشارکت و نقش نویسندگان

محرابی: ایده و طراحی مطالعه، شنبه‌زاده و ولی‌نژادی: انجام پیش‌پردازش و آماده‌سازی مجموعه داده و نگارش نسخه اولیه مقاله، افراش: انجام داده کاوی و آنالیز آماری، نوپور: آنالیز و تفسیر نتایج، امرابی و محمدی: گزارش‌دهی نتایج و نگارش بحث. لازم به ذکر است که همه نویسندگان نتایج را بررسی نموده و نسخه نهایی مقاله را تایید نمودند.

- <https://doi.org/10.1111/ijd.15288>
PMid:33128460
- [29] Afhami N. Prediction of diabetic chronic kidney disease progression using data mining techniques. *Int J Comput Sci Engin* 2018; 7: 35-40.
- [30] Boukenze B, Haqiq A, Mousannif H, editors. Predicting chronic kidney failure disease using data mining techniques. *Int Symp Ubiquitous Networking* 2016. <https://doi.org/10.5121/csit.2016.60501>
- [31] Wu B, Li D, Xu T, Luo M, He Z, Li Y. Proton pump inhibitors associated acute kidney injury and chronic kidney disease: data mining of US FDA adverse event reporting system. *Sci Rep* 2021; 11: 3690. <https://doi.org/10.1038/s41598-021-83099-y>
PMid:33574396 PMCID:PMC7878877
- [32] Xia P, Gao K, Xie J, Sun W, Shi M, Li W, et al. Data mining-based analysis of chinese medicinal herb formulae in chronic kidney disease treatment. *Evid Based Complement Alternat Med* 2020; 2020: 9719872. <https://doi.org/10.1155/2020/9719872>
PMid:32047530 PMCID:PMC7003280
- [33] Kumar A, Kumar P, Srivastava A, Kumar VA, Vengatesan K, Singhal A, editors. Comparative analysis of data mining techniques to predict heart disease for diabetic patients. *Int Confer Adv Comput Data Sci* 2020. https://doi.org/10.1007/978-981-15-6634-9_46
- [34] Chaurasia V, Pal S, Tiwari BB. Prediction of benign and malignant breast cancer using data mining techniques. *Journal of Algorithms & Computational Technology*. 2018 Jun;12 (2):119-26
<https://doi.org/10.1177/1748301818756225>
- [35] Amin MS, Chiam YK, Varathan KD. Identification of significant features and data mining techniques in predicting heart disease. *Telematics and Informatics*. 2019 Mar 1;36:82-93. <https://doi.org/10.1016/j.tele.2018.11.007>
- [36] Tougui I, Jilbab A, El Mhamdi J. Heart disease classification using data mining tools and machine learning techniques. *Health and Technology*. 2020 Sep;10(5):1137-44. <https://doi.org/10.1007/s12553-020-00438-1>
- [37] Patwardhan MB, Kawamoto K, Lobach D, Patel UD, Matchar DB. Recommendations for a clinical decision support for the management of individuals with chronic kidney disease. *Clin J Am Soc Nephrol* 2009; 4: 273-283. <https://doi.org/10.2215/CJN.02590508>
PMid:19176797 PMCID:PMC2637586
- [38] Rashed-Al-Mahfuz M, Haque A, Azad A, Alyami SA, Quinn JM, Moni MA. Clinically applicable machine learning approaches to identify attributes of chronic kidney disease (CKD) for use in Low-Cost diagnostic screening. *IEEE J Transl Eng Health Med* 2021; 9: 1-11. <https://doi.org/10.1109/JTEHM.2021.3073629>
<https://doi.org/10.1109/JTEHM.2021.3050925>
PMid:33542859 PMCID:PMC7851059
- [39] Khoong EC, Karliner L, Lo L, Stebbins M, Robinson A, Pathak S, et al. A pragmatic cluster randomized trial of an electronic clinical decision support system to improve chronic kidney disease management in primary care: design, rationale, and implementation experience. *JMIR Res Protoc* 2019; 8: e14022. <https://doi.org/10.2196/14022>
PMid:31199334 PMCID:PMC6594214
- [40] Pesce F, Diciolla M, Binetti G, Naso D, Ostuni VC, Di Noia T, et al. Clinical decision support system for end-stage kidney disease risk estimation in IgA nephropathy patients. *Nephrol Dial Transplant* 2016; 31: 80-86. <https://doi.org/10.1093/ndt/gfv232>
PMid:26047632
- [41] Yadollahpour A, Nourozi J, Mirbagheri SA, Simancas-Acevedo E, Trejo-Macotela FR. Designing and implementing an ANFIS based medical decision support system to predict chronic kidney disease progression. *Front Physiol* 2018; 9: 1753. <https://doi.org/10.3389/fphys.2018.01753>
PMid:30574095 PMCID:PMC6291481
- [42] Afrash MR, Khalili M, Salekde MS. A comparison of data mining methods for diagnosis and prognosis of heart disease. *International Journal of Advanced Intelligence* prioritizing Iran's target export markets. *Iran J Pharmace Res* 2019; 18: 546. (Persian).
- [15] Yusefzadeh H, Hadian M, Gorji HA, Ghaderi H. Assessing the factors associated with Iran's intra-industry trade in pharmaceuticals. *Global J Health Sci* 2015; 7: 311. <https://doi.org/10.5539/gjhs.v7n5p311>
- [16] Yusefzadeh H, Rezapour A, Lotfi F, Azar FE, Nabilo B, Gorji HA, et al. A Study of comparative advantage and intra-industry trade in the pharmaceutical industry of Iran. *Global J Health Sci* 2015; 7: 295. (Persian). <https://doi.org/10.5539/gjhs.v7n6p295>
- [17] Fazaeli AA, Fazaeli AA, Hamidi Y, Moeini B, Valinejadi A. Analysis of iranian household financial participation in the health system: decomposition of the concentration index approach. *Koomesh* 2018; 358-368. (Persian).
- [18] Shojaei S, Yousefi M, Ebrahimipour H, Valinejadi A, Tabesh H, Fazaeli S. Catastrophic health expenditures and impoverishment in the households receiving expensive interventions before and after health sector evolution plan in Iran: Evidence from a big hospital. *Koomesh* 2018; 283-290. (Persian).
- [19] Yousefi M, Aliani S, Valinejadi A, Rezazadeh A, Khorsand A, Fazaeli S, Ebrahimipour H. Effect of "Iran's health system evolution plan" and "tariff change" on financial performance of para-clinic units in a big tertiary hospital in Iran. *Koomesh* 2018; 20. (Persian).
- [20] Askari-Majdabadi H, Valinejadi A, Mohammadpour A, Bouraghi H, Abbasy Z, Alaei S. Use of health information technology in patients care management: a mixed methods study in Iran. *Acta Informatica Medica* 2019; 27: 311. <https://doi.org/10.5455/aim.2019.27.311-317>
PMid:32210498 PMCID:PMC7085310
- [21] Mohammadi A, Valinejadi A, Sakipour S, Hemmat M, Zarei J, Majdabadi HA. Improving the distribution of rural health houses using elicitation and GIS in Khuzestan province (the southwest of Iran). *Int J Health Policy Manag* 2018; 7: 336. (Persian). <https://doi.org/10.15171/ijhpm.2017.101>
PMid:29626401 PMCID:PMC5949224
- [22] Milani RV, Oleck SA, Lavie CJ. Medication errors in patients with severe chronic kidney disease and acute coronary syndrome: the impact of computer-assisted decision support. *Mayo Clin Proc* 2011; 86: 1161-1164. <https://doi.org/10.4065/mcp.2011.0290>
PMid:22134934 PMCID:PMC3228615
- [23] Samal L, D'Amore JD, Bates DW, Wright A. Implementation of a scalable, web-based, automated clinical decision support risk-prediction tool for chronic kidney disease using C-CDA and application programming interfaces. *J Am Med Inform Assoc* 2017; 24: 1111-1115. <https://doi.org/10.1093/jamia/ocx065>
PMid:29016969 PMCID:PMC6580936
- [24] Alipour J, Safari Lafti S, Askari Majdabadi H, Yazdiyani A, Valinejadi A. Factors affecting hospital information system acceptance by caregivers of educational hospitals based on technology acceptance model (TAM): A study in Iran. *lioab J* 2016; 119-123.
- [25] Ziari A, Ansari M, Valinejadi A. The gap between the service quality and patients' expectations in amir-al-momenin hospital of Semnan university of medical sciences in 2016, Semnan, Iran. *Koomesh* 2018; 221-227. (Persian).
- [26] Ennis J, Gillen D, Rubenstein A, Worcester E, Brecher ME, Asplin J, Coe F. Clinical decision support improves physician guideline adherence for laboratory monitoring of chronic kidney disease: a matched cohort study. *BMC Nephrol* 2015; 16: 163. <https://doi.org/10.1186/s12882-015-0159-5>
PMid:26471846 PMCID:PMC4608162
- [27] Exarchos I, Rogers AA, Aiiani LM, Gross RE, Clifford GD, Pedersen NP, Willie JT. Supervised and unsupervised machine learning for automated scoring of sleep-wake and cataplexy in a mouse model of narcolepsy. *Sleep* 2020; 43. <https://doi.org/10.1093/sleep/zsz272>
PMid:31693157 PMCID:PMC7215268
- [28] Singh Pathania Y, Budania A. Artificial intelligence in dermatology: "unsupervised" versus "supervised" machine learning. *Int J Dermatol* 2021; 60: e28-e29.

- [50] Sobrinho A, Queiroz ACDS, Da Silva LD, Costa ED, Pinheiro ME, Perkusich A. Computer-aided diagnosis of chronic kidney disease in developing countries: A comparative analysis of machine learning techniques. *IEEE Access* 2020; 8: 25407-25419. <https://doi.org/10.1109/ACCESS.2020.2971208>
- [51] Abdullah AA, Hafidz SA, Khairunizam W, editors. Performance comparison of machine learning algorithms for classification of chronic kidney disease (CKD). *J Phys Confer Series* 2020; IOP Publishing. <https://doi.org/10.1088/1742-6596/1529/5/052077>
- [52] Senan EM, Al-Adhaileh MH, Alsaade FW, Aldhyani TH, Alqarni AA, Alsharif N, et al. Diagnosis of chronic kidney disease using effective classification algorithms and recursive feature elimination techniques. *J Health Care Engin* 2021; 2021. <https://doi.org/10.1155/2021/1004767> PMID:34211680 PMCID:PMC8208843
- [53] Al-Hyari AY, Al-Taei AM, Al-Taei MA, editors. Clinical decision support system for diagnosis and management of chronic renal failure. 2013 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT); 2013; IEEE. <https://doi.org/10.1109/AEECT.2013.6716440>
- [44] Levey AS, Coresh J. Chronic kidney disease. *The lancet* 2012; 379: 165-180. [https://doi.org/10.1016/S0140-6736\(11\)60178-5](https://doi.org/10.1016/S0140-6736(11)60178-5)
- Paradigms. 2020;16 (1):88-97. <https://doi.org/10.1504/IJAIP.2020.106692>
- [43] Hossin M, SulaimanMN. A review on evaluation metrics for data classification evaluations. *Int J Data Min Knowledge Manag Proc* 2015; 5: 1.
- [45] Fraser SD, Roderick PJ, May CR, McIntyre N, McIntyre C, Fluck RJ, Shardlow A, Taal MW. The burden of comorbidity in people with chronic kidney disease stage 3: a cohort study. *BMC Nephrol* 2015; 16: 1-11. <https://doi.org/10.1186/s12882-015-0189-z> PMID:26620131 PMCID:PMC4666158
- [46] Krishnamurthy S, Ks K, Dovgan E, Luštrek M, Gradišek Piletič B, Srinivasan K, et al, editors. Machine learning prediction models for chronic kidney disease using national health insurance claim data in Taiwan. *Healthcare*; 2021: Multidisciplinary Digital Publishing Institute. <https://doi.org/10.1101/2020.06.25.20139147>
- [47] RoyMS, Ghosh R, Goswami D, Karthik R, editors. Comparative analysis of machine learning methods to detect chronic kidney disease. *J Phys Confer Series* 2021; IOP Publishing. <https://doi.org/10.1088/1742-6596/1911/1/012005>
- [48] Darveshwala AY, Singh D, Farooqui Y, editors. Chronic kidney disease stage identification in HIV infected patients using machine learning. 2021 5th International Conference on Computing Methodologies and Communication (ICCMC); 2021; IEEE. <https://doi.org/10.1109/ICCMC51019.2021.9418430>
- [49] Almansour NA, Syed HF, Khayat NR, Altheeb RK, Juri RE, Alhiyafi J, et al. Neural network and support vector machine for the prediction of chronic kidney disease: A comparative study. *Comput Biol Med* 2019; 109: 101-111. <https://doi.org/10.1016/j.compbiomed.2019.04.017> PMID:31054385

Design and implementation of an intelligent clinical decision support system for diagnosis and prediction of chronic kidney disease

Mohammad Reza Afrash (Ph.D Candidate)¹, Ali Valinejadi (Ph.D)², Morteza Amraei (Ph.D)³, Raof Noupor (M.Sc)⁴, Nahid Mehrabi (Ph.D)⁵, Sara Mohammadi (M.Sc)⁶, Mostafa Shanbehzadeh (Ph.D)^{*7}

1 - Student Research Committee, School of Allied Medical Sciences, ShahidBeheshti University of Medical Sciences, Tehran, Iran

2 – Dept. of Health Information Technology, School of Allied Medical Sciences, Semnan University of Medical Sciences, Semnan, Iran

3- Dept. of Health Information Technology, School of Allied Medical Sciences, Lorestan University of Medical Sciences, Khorramabad, Iran

4- Dept. of Health Information Technology, School of Paramedical, Tehran University of Medical Sciences, Tehran, Iran

5- Dept. of Health Information Technology, AJA University of Medical Sciences (AJAUMS), Tehran, Iran

6- Dept. of Operating Room, School of Allied Medical Sciences, Ilam University of Medical Sciences, Ilam, Iran

7- Dept. of Health Information Technology, School of Paramedical, Ilam University of Medical Sciences, Ilam, Iran

* Corresponding author. +98 9300833691

Mostafa.shanbehzadeh@gmail.com

Received: 5 Aug 2021; Accepted: 28 Nov 2021

Introduction: Chronic kidney disease (CKD) is one of the most important public health concerns worldwide. The steady increase in the number of people with End-stage renal disease (ESRD) needing a kidney transplant to survive and incur high costs, highlights early diagnosis and treatment of the disease. This study aimed to design a Clinical Decision Support System (CDSS) for diagnosing CKD and predicting the advanced stage to achieve better management and treatment of the disease.

Materials and Methods: In this retrospective and developmental study, we studied the records of 600 suspected CKD cases with 22 variables referred to ShahidLabafinejad Hospital in Tehran from 2019 to 2020. Data mining algorithms such as Naïve Bayesian, Random Forest, Multilayer Perceptron neural network, and J-48 decision tree were developed based on extracted variables. Then the recital of selected models was compared by some performance indices and 10-fold cross-validation. Finally, the most appropriate prediction model in terms of performance was implemented using the C # programming language.

Results: Random Forest classification algorithm with an accuracy of 99.8% and 88.66%, specificity of 100% and 93.8%, the sensitivity of 99.75% and 88.7%, f-measure of 99.8% and 88.7%, kappa score of 99.4% and 82.73%, and ROC of 100% and 90.52% was identified as the best data mining model for CKD diagnosis and prediction respectively.

Conclusion: The developed MC-DMK system based random Forest can be used practically in clinical settings.

Keywords: Chronic Kidney Failure, Glomerular Filtration Rate, Clinical Decision Support Systems, Data Mining; Computer Neural Networks, Algorithm