

# مدل یادگیری ماشین ابیاشته برای دسته‌بندی و پیش‌بینی بیماری‌های کبدی

باک آذرنوید<sup>۱\*</sup>، محسن عبدالحسین‌زاده<sup>۲</sup>، حجت امامی<sup>۳</sup>

استادیار گروه ریاضی و علوم کامپیوتر، دانشکده علوم پایه، دانشگاه بناب، بناب، ایران<sup>۱\*</sup>

استادیار گروه ریاضی و علوم کامپیوتر، دانشکده علوم پایه، دانشگاه بناب، بناب، ایران<sup>۲</sup>

دانشیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه بناب، بناب، ایران<sup>۳</sup>

## چکیده

بیماری‌های کبدی یکی از علل اصلی مرگ‌ومیر هستند که تأثیر عمیقی بر زندگی افراد دارند و تشخیص آن‌ها در مراحل اولیه بسیار حیاتی است. هدف این پژوهش، توسعه و ارزیابی مدل یادگیری ماشین ابیاشته (SML) برای تشخیص و پیش‌بینی دقیق بیماری‌های کبدی است. مدل SML با استفاده از ساختار دولایه، الگوریتم‌های مختلف را ترکیب کرده تا مشکل بیش‌برازش را برطرف کند و دقت پیش‌بینی را افزایش دهد. در لایه نخست، چهار الگوریتم شامل درخت تصادفی نامحدود (ET)، درخت تصمیم (DT)، جنگل تصادفی (RF) و تقویت گرادیان شدید (XGB) برای پیش‌بینی اولیه استفاده می‌شوند. در لایه دوم، الگوریتم رگرسیون توابعی (LR) بر اساس خروجی لایه نخست آموزش داده می‌شود تا پیش‌بینی نهایی انجام شود. تنظیم پارامترها با الگوریتم جستجوی شبکه توری (GS) انجام شده است. داده‌های مورد استفاده شامل ۶۱۵ نمونه داده با دوازده ویژگی از پایگاه دانشگاه کالیفرنیا در ایروین است که ۷۰٪ برای آموزش و ۳۰٪ برای آزمایشی اختصاص یافته است. نتایج اعتبارسنجی متقابل  $k=5$  نشان می‌دهد که مدل پیشنهادی با صحت ۰.۹۹۴۰ و معیار F1 برابر ۰.۹۸۸۰، عملکرد برتری نسبت به سایر روش‌ها دارد. این پژوهش می‌تواند به کاهش مرگ‌ومیر ناشی از بیماری‌های کبدی کمک شایانی کند.

وازگان کلیدی: بیماری‌های کبد، تشخیص زودهنگام، یادگیری ماشین، مدل یادگیری ماشین ابیاشته، اعتبارسنجی متقابل.

## Stacking machine learning model for classification and prediction of liver diseases

Babak Azarnavid<sup>1\*</sup>, Mohsen Abdolhosseinzadeh<sup>2</sup>, Hojjat Emami<sup>3</sup>

Assistant Professor, Department of Mathematics and Computer Science, Basic Science Faculty,  
University of Bonab, Bonab, Iran<sup>1\*</sup>

Assistant Professor, Department of Mathematics and Computer Science, Basic Science Faculty,  
University of Bonab, Bonab, Iran<sup>2</sup>

Associate Professor, Department of Computer Engineering, Faculty of Engineering, University  
of Bonab, Bonab, Iran<sup>3</sup>

### Abstract

Liver diseases are among the leading causes of mortality worldwide, deeply influencing individuals' lives, often at younger ages when they are in the prime of their personal and professional lives. The insidious nature of these diseases lies in their early initial symptoms, which frequently goes unnoticed until the condition has progressed to an advanced stage. This delay in diagnosis not only diminishes the chances of successful treatment but also places an immense emotional and financial burden on patients as well as families. Early detection is therefore critical, as it can significantly alter the course of the disease, improving survival rates and quality of life. However, traditional diagnostic methods often fall

\* Corresponding author

\* نویسنده عهده‌دار مکاتبات

• تاریخ ارسال مقاله: ۱۴۰۳/۱۱/۰۷ • تاریخ پذیرش: ۱۴۰۴/۰۴/۲۹ • تاریخ انتشار: ۱۴۰۴/۰۶/۲۲ • نوع مطالعه: پژوهشی

سال ۱۴۰۴ شماره ۲ پیاپی ۶۴

short in terms of speed, accuracy, and accessibility, particularly in resource-limited settings. This underscores the urgent need for innovative approaches to liver disease detection and its management. Machine learning (ML) has been emerged as a powerful tool in this regard, offering the potential to revolutionize how we diagnose and predict liver diseases. By leveraging vast datasets—ranging from clinical records and laboratory results to imaging data—ML algorithms can uncover complex patterns and correlations that may elude human experts. These insights can lead to earlier and more accurate diagnoses, enabling timely interventions that can save lives. Among the various ML approaches, stacked machine learning (SML) models stand out for their ability to combine the strengths of multiple algorithms, mitigating the limitations of individual models and enhancing overall performance. This research focuses on developing and evaluating an SML model specifically designed for the accurate diagnosis, classification, and prediction of liver diseases, with the goal of addressing some of the most pressing challenges in this field.

The proposed SML model employs a sophisticated two-layer architecture to tackle common issues such as overfitting and improving prediction accuracy. In the first layer, the model integrates four robust base learner algorithms: Extremely Randomized Trees (ET), Decision Tree (DT), Random Forest (RF), and Extreme Gradient Boosting (XGB). Each of these algorithms contributes unique strengths, such as handling high-dimensional data, capturing non-linear relationships, and reducing variance. The predictions generated by these base learners are then fed into the second layer, where a Logistic Regression (LR) algorithm synthesizes the outputs to produce the final prediction. This layered approach ensures that the model benefits from the collective intelligence of multiple algorithms, resulting in more reliable and precise outcomes. To further optimize performance, the Grid Search (GS) algorithm was employed to fine-tune the parameters of the learning algorithms, ensuring that the model operates at its full potential. This study employs dataset from the University of California, Irvine (UCI) Machine Learning Repository. A sample size of 615 instances has been utilized to implement the proposed methodologies, with a stratified division of 70% for training and 30% allocated for testing purposes. The results of this research seems to be highly promising. Evaluation based on 5-fold cross-validation demonstrates that the proposed SML model outperforms existing methods, achieving an impressive 0.9940 accuracy and a 0.9880 F1-score on the test data. These metrics not only highlight the model's exceptional predictive capabilities but also underscore its potential to serve as a valuable tool for clinicians in real-world settings. By providing accurate and timely diagnoses, the SML model can help reduce the mortality and morbidity associated with liver diseases, offering hope to patients and their families.

Beyond the technical achievements, the human impact of this research cannot be overstated. For patients, the SML model represents a lifeline—a chance to detect liver diseases early, when treatment seems most effective, and to avoid the devastating consequences of late-stage diagnoses. For healthcare providers, it offers a reliable and efficient diagnostic tool that can enhance decision-making and improve patient outcomes. Also, for society as a whole, it signifies a step forward in the fight against a disease that disproportionately affects vulnerable populations, including those in underserved regions where access to advanced medical care is limited. In essence, this research is not just about developing a sophisticated algorithm; it is also about harnessing the power of machine learning to make a tangible difference in people's lives. By bridging the gap between cutting-edge technology and human care, the proposed SML model embodies the potential of computer science to address some of the most critical health challenges of our time. It is a testament to the transformative power of innovation, compassion, and collaboration in the pursuit of better health for all.

**Keywords:** Liver diseases, Early Diagnosis, Machine Learning, Cumulative Machine Learning Model, Cross-Validation.

بلکه کیفیت زندگی میلیون‌ها نفر در سراسر جهان را نیز بهشت تحت تأثیر قرار می‌دهند.

بیماری‌های کبدی ناشی از عوامل مختلفی هستند. ویروس‌ها و انگل‌ها می‌توانند کبد را آلوده کرده و باعث التهاب E و اختلال در عملکرد آن شوند. هپاتیت‌های A, B, C, D و رایج‌ترین ویروس‌هایی هستند که عفونت‌های کبدی ایجاد می‌کنند؛ همچنین مصرف بیش از حد الکل و تجمع چربی در کبد می‌تواند منجر به آسیب‌های کبدی مانند هپاتیت الکلی، بیماری کبد چرب و سیروز شود<sup>[۳]</sup>. بیماری مزمن کبدی و می‌تواند به نتایج شدیدی مانند عدم جبران کبدی و هپاتوسولار کارسینوما منجر شود؛ بهویژه در افرادی که دچار

## ۱- مقدمه

کبد نقش حیاتی در عملکردهای مختلف بدن، از جمله سمزدایی، متابولیسم و سنتز پروتئین‌ها دارد و سلامت آن برای رفاه کلی ضروری است. بیماری‌های کبدی به عنوان یکی از چالش‌های مهم بهداشتی جهانی شناخته می‌شوند که بدليل شیوع بالا، امکان بروز عوارض شدید و تأثیرات عمیق بر نرخ مرگ‌ومیر، توجه ویژه‌ای را به خود جلب کرده‌اند. هر ساله حدود دو میلیون نفر بدليل مشکلات مربوط به کبد از جمله هپاتیت ویروسی و سیروز جان خود را از دست می‌دهند [۱,۲]. این بیماری‌ها نه تنها بر نرخ مرگ‌ومیر تأثیر می‌گذارند،

فصلنامه



می‌توان به مدل تقویت سازگار (آدابوست)<sup>۱</sup>، جنگل تصادفی [۱۱]، شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان [۱۲]، درخت تصمیم، رگرسیون تراپری [۱۳] و درخت طبقه‌بندی افزایش گرادیان مبتنی بر هیستوگرام<sup>۲</sup> [۱۴] اشاره کرد. این روش‌ها به کارایی قابل قبول دست یافته‌اند؛ اما کارایی کسب شده هنوز با حالت ایده‌آل فاصله داشته و تلاش زیادی برای بهبود کارایی روش‌های موجود نیاز است؛ بنابراین در این پژوهش، چندین مدل یادگیری ماشین مورد ارزیابی قرار گرفته و درنهایت مدل یادگیری ماشین اینباشت (SML) معرفی شد. هدف مدل پیشنهادی بهبود دقت پیش‌بینی از طریق ترکیب توانایی الگوریتم‌های متعدد یادگیری ماشین است؛ به همین منظور مدل پیشنهادی SML، با ترکیب پنج مدل داده‌محور شامل دسته‌بندی نهایت تصادفی (ET)، درخت تصمیم (DT)، جنگل تصادفی (RF)، تقویت گرادیان شدید (XGB) و رگرسیون تراپری (LR) - در یک ساختار لایه‌ای یک مدل پیش‌بینی‌کننده توانمند ایجاد کرده که بر مشکل پیش‌برازش و کم‌برازش چیره و موجب بهبود دقت پیش‌بینی شده است.

با اختصار، نوآوری‌های پژوهش حاضر را می‌توان در موارد زیر خلاصه کرد:

- مدل‌سازی مسئله تشخیص و پیش‌بینی بیماری‌های کبدی به صورت یک مسئله دسته‌بندی ناظارتی<sup>۳</sup>: مسئله پیش‌بینی بیماری‌های کبدی به صورت یک مسئله یادگیری ماشین ناظارتی مدل‌سازی شده است که موجب می‌شود به سادگی بتوان از طیف وسیعی از الگوریتم‌های یادگیری ماشین و تحلیل داده برای حل مسئله استفاده کرد.

- ارائه مدل یادگیری ماشین اینباشت: مدل SML با ترکیب هوشمندانه الگوریتم‌های یادگیری متعدد در یک ساختار دو لایه‌ای موجب بهبود تشخیص و دسته‌بندی بیماری‌های کبدی می‌شود. مدل پیشنهادی با بهره‌گیری از چهار مدل یادگیر پایه شامل ET، RF، DT و XGB در لایه نخست و الگوریتم LR در لایه دوم مشکل پیش‌برازش را به نحو مطلوبی برطرف کرده و موجب بهبود پایداری و کارایی مدل‌های منفرد می‌شود؛ همچنین برای تنظیم فرآپارامترهای الگوریتم‌های یادگیر پایه و فرآمدل از الگوریتم جستجوی شبکه توری (GS) استفاده شده است.

<sup>1</sup> Adaptive boosting

<sup>2</sup> Histogram-based gradient boosting classification tree (HGBoost)

<sup>3</sup> Supervised

فیروز متوسط تا پیشرفته هستند<sup>[۴]</sup>. پیشرفته بیماری‌های کبدی به طور معمول تا زمانی که به مراحل پیشرفته مانند سیروز برسد، نادیده گرفته می‌شود؛ جایی که آسیب غیرقابل برگشت رخ داده است. این موضوع اهمیت تشخیص زودهنگام و مداخله را برجسته می‌کند و ضرورت استفاده از روش‌های مؤثر برای پیش‌بینی و تشخیص بیماری‌های کبدی را در مراحل اولیه وقت می‌بخشد.

پیشرفتهای اخیر در پردازش داده‌ها و یادگیری ماشین فرصت‌های امیدبخشی برای بهبود پیش‌بینی بیماری‌های کبدی و عوارض آن‌ها ارائه می‌دهند. با تجزیه و تحلیل داده‌های بالینی، شخصی و مولکولی، مدل‌های یادگیری ماشین می‌توانند الگوها و عوامل خطر را شناسایی کنند که ممکن است از طریق روش‌های تشخیص سنتی به راحتی قابل مشاهده نباشند. این رویکرد می‌تواند مداخلات به موقع را تسهیل و به طور بالقوه از پیشرفته بیماری کبدی جلوگیری کند و باز سلامت مرتبط را کاهش دهد. با توجه به افزایش شیوع بیماری‌های کبدی به دلیل عواملی مانند چاقی، سوءصرف الكل و عفونت‌های ویروسی استفاده از فناوری برای بهبود پیش‌بینی به منظور به کارگیری در ابتکارات بهداشت عمومی که هدف آن‌ها مبارزه با بیماری کبد است، ضروری است.

ظهور هوش مصنوعی، بهویژه روش‌های یادگیری ماشین و داده‌کاوی فرصت‌های قابل توجهی را برای ارتقای خدمات بهداشتی از طریق تجزیه و تحلیل مجموعه داده‌های عظیم و شناسایی الگوهای معنی‌دار ارائه می‌دهد<sup>[۵]</sup>. با وجود این پیشرفتهای جامعه پژوهشی همچنان در پذیرش کامل این فناوری‌ها تردید دارد که منجر به عدم استفاده از پتانسیل عظیم آن می‌شود<sup>[۶]</sup>. یادگیری ماشین به عنوان یک ابزار پیشرفته در تشخیص بیماری‌ها بهویژه بیماری‌های کبدی و هپاتیت C اهمیت ویژه‌ای دارد. با تحلیل داده‌های گسترده پژوهشی و زیستی، الگوریتم‌های یادگیری ماشین می‌توانند الگوهای پیچیده‌ای را شناسایی کنند که ممکن است از دید انسان پنهان مانده باشند. این روش‌ها قابلیت افزایش دقت در تشخیص زودهنگام بیماری‌های کبدی را دارند، که به درمان سریع‌تر و مؤثرتر بیماران کمک می‌کنند<sup>[۷]</sup>؛ همچنین یادگیری ماشین می‌تواند در پیش‌بینی روند پیشرفته بیماری و پاسخ به درمان نیز مؤثر باشد و به پزشکان اطلاعات بهتری برای تصمیم‌گیری‌های بالینی ارائه دهد. با توجه به هزینه بالای مادی و انسانی این بیماری‌ها در سطح جهانی، بهره‌گیری از یادگیری ماشین می‌تواند نقشی کلیدی در بهبود نتایج درمانی و کاهش عوارض ناشی از بیماری‌های کبدی ایفا کند.

در سال‌های اخیر چندین روش مبتنی بر یادگیری ماشین برای تشخیص بیماری‌های کبدی ارائه شده است؛ از جمله

• ارزیابی روش پیشنهادی: نتایج آزمایش‌ها بر روی مدل استاندارد بیماری‌های کبدی و بر مبنای استراتژی اعتبارسنجی متقابل با  $k=5$  نشان می‌دهد که مدل پیشنهادی SML بهبود قابل توجهی نسبت به سایر مدل‌های ماشین کسب کرده است. مدل SML بر روی مجموعه‌داده آزمایشی بهترین مقادیر ۰.۹۴۰، ۰.۹۸۰ و ۰.۹۸۳ را بر معیارهای صحت، معیار F1، میانگین قدرمطلق خطأ (MAE) و جذر میانگین مربعات خطأ (RMSE) کسب کرده که بسیار بهتر از کارایی کسب شده به وسیله سایر مدل‌ها در ادبیات موضوع است. این موضوع نشان می‌دهد که مدل پیشنهادی می‌تواند به عنوان ابزاری مؤثر در تشخیص زودهنگام بیماری‌های کبدی مورد استفاده قرار گیرد.

ساختار ادامه مقاله به صورت زیر سازماندهی شده است. در بخش دوم کارهای مرتبط در زمینه تشخیص و پیش‌بینی بیماری‌های کبدی بررسی، در بخش سوم به جزئیات روش پیشنهادی پرداخته، ارزیابی روش پیشنهادی به همراه نتایج آزمایش‌ها و بحث بر روی نتایج در بخش چهار و نتیجه‌گیری مقاله و نیز ارائه پیشنهادهایی برای انجام پژوهش‌های بیشتر در بخش پنجم آورده شده است.

## ۲- کارهای مرتبط

با توجه به این که بسیاری از آزمایش‌های پزشکی سنتی به لحاظ هزینه و زمان به صرفه نیستند و برای ارائه تشخیص سریع و کم‌هزینه با چالش‌هایی مواجه‌اند، نیاز فوری و مبرمی به روش‌های تشخیصی جایگزین احساس می‌شود. متخصصان بهداشت از روش‌های آسیب‌شناسی مختلفی برای تفسیر گزارش‌های پزشکی و درنتیجه ارزیابی مؤثر و ضعیت بیماران استفاده می‌کنند. پیشرفت‌های اخیر در هوش مصنوعی و توسعه روش‌های یادگیری ماشین، تشخیص بیماری‌ها را بهبود داده و به پزشکان اجازه می‌دهد یافته‌های بالینی را با روش‌های پیشرفته تحلیل داده ادغام کنند [۱۲، ۱۴]. در ادامه به بررسی مهم‌ترین روش‌های یادگیری ماشین در حوزه پیش‌بینی بیماری‌های کبدی می‌پردازیم.

عارف و همکاران [۱۵] کاربرد الگوریتم‌های یادگیری ماشین را برای شناسایی الگوها و ارائه پیش‌بینی‌های ارجشمند جهت تسهیل فرایندهای بالینی تصمیم‌گیری، بررسی کردن که مشتمل بر روش غیرت‌هاجمی و کم‌هزینه به ویژه برای بیمارانی است که نیاز به پایش دوره‌ای دارند؛ بر اساس نتایج آن‌ها مدل رگرسیون ترابری، مؤثرترین طبقه‌بندی برای پیش‌بینی پیشرفت هپاتیت C معرفی شده است. ترلسن و همکاران [۱۶] با به کارگیری روش‌های یادگیری ماشین، تحلیلی از ساختار داده‌ها، به منظور پاسخ اولیه به پرسش‌های بالینی و تحلیل داده‌های آزمایشگاهی ارائه کردند. سینگ و مانتری [۱۷] یک سازوکار پشتیبانی تصمیم‌گیری بالینی را مورد مطالعه قرار داده است که از روش‌های داده‌کاوی برای

پایش و ارائه خدمات بهداشتی استفاده می‌کند. آن‌ها با بررسی اطلاعات بیماری‌هایی مانند هپاتیت، مشکلات پوستی، بیماری‌های کبدی و اوتیسم سعی در افزایش دقت اثربخشی تصمیم‌گیری‌های بالینی داشتند.

چالش عدم تعادل داده‌ها، موانع قابل توجهی را در یادگیری ماشین، به ویژه در حوزه‌های مرتبط با سلامت مانند پژوهش‌ها بر روی بیماری‌های کبدی و ویروس هپاتیت C ایجاد می‌کند. یک مجموعه‌داده نامتعادل که با توزیع نابرابر طبقه‌ها مشخص می‌شود، تمایل به تولید مدل‌های پیش‌بینی کننده جانبی دارد به نفع طبقه پیشینه را دارد که می‌تواند بر عملکرد مدل تأثیر منفی بگذارد. برای مقابله با این مشکل می‌توان از روش بیش‌نمونه‌گیری اقلیت مصنوعی<sup>۱</sup> (SMOTE) استفاده کرد، که نمونه‌های مصنوعی از طبقه کمینه را برای افزایش نمایش آن به منظور تسهیل تولید و یادگیری الگوهای کلی به کار می‌برد [۱۸]. لی و همکاران [۱۹]، یک روش طبقه‌بندی چندطبقه را ارائه کردند که با تحلیل ویژگی‌های خون بیماران احتمال بروز عفونت ویروس هپاتیت C را بدست می‌آورد؛ همچنین با استفاده از روش بیش‌نمونه‌گیری، اقلیت مصنوعی و روش آبشاری دومرحله‌ای، مدل الگوریتم‌های جنگل تصادفی<sup>۲</sup> و رگرسیون ترابری<sup>۳</sup> را با هم ادغام کردند و به وسیله الگوریتم کلونی مصنوعی زنبور عسل<sup>۴</sup> آستانه ترکیب مؤثر مدل را بهینه‌سازی کردند. ارشادی و سیفی [۲۰] با بررسی روش‌های انتخاب، کاهش و خوش‌بندی ویژگی‌ها و با معرفی یک روش انتخاب ویژگی به دنبال افزایش کارایی مدل‌های طبقه‌بندی در تشخیص پزشکی بودند؛ در ضمن روش پیشنهادی خود را با الگوریتم ژنتیک<sup>۵</sup> و بهینه‌سازی ازدحام ذرات<sup>۶</sup> در جهت افزایش دقت طبقه‌بندی ترکیب کردند؛ همچنین ترکیب مدل‌های یادگیری ماشین با الگوریتم‌های بهینه‌سازی گلوگاهی دیپر<sup>۷</sup> و بهینه‌سازی ازدحام ذرات [۲۱]، تبرید شبیه‌سازی شده<sup>۸</sup>، برای افزایش دقت و کارایی الگوریتم‌ها در تشخیص و پیش‌بینی کارسینوم سلول کبدی [۹، ۲۱] مورد توجه پژوهش‌گران قرار گرفته است.

یاغان اوغلو [۲۲] از فرایندهای داده‌کاوی برای کشف الگوها و تخمين شیوع ویروس هپاتیت C استفاده کرده است. در این پژوهش با استفاده از تجزیه و تحلیل جامع و تجسم داده‌ها، ویژگی‌های کلیدی مرتبط با این بیماری شناسایی شده است. در مرجع [۲۰] الگوریتم‌های آدبوست و جنگل

<sup>1</sup> Synthetic minority oversampling technique

<sup>2</sup> Hepatitis C virus

<sup>3</sup> Cascade two-stage method

<sup>4</sup> Random forest

<sup>5</sup> Logistic regression

<sup>6</sup> Artificial bee colony

<sup>7</sup> Genetic algorithm

<sup>8</sup> Particle swarm optimization

<sup>9</sup> Dipper throated optimization

<sup>10</sup> Simulated annealing

عملی، یک رابط کاربری بهمنظور دریافت و پردازش داده‌های بیماران کبدی طراحی کردند. ارجوی و کرمانی [۲۷] از مجموعه‌داده‌های هپاتیت C موجود در مخزن UCI<sup>۱۱</sup> استفاده کرده و از روش چهارمرحله‌ای شامل پیش‌پردازش داده‌ها، داده‌کاوی، طراحی و تحلیل سامانه با ارائه یک محیط کاربری در نرم‌افزار MATLAB استفاده کردند. آن‌ها با به کاربستن سه الگوریتم داده‌کاوی پرسپترون چندلایه، شبکه بیزی و درخت تصمیم از روش اعتبارسنجی متقاطع ده‌تایی به ارزیابی عملکرد پرداختند. فرغالی و همکاران [۲۸] یادگیری ماشین را برای پیش‌بینی ویروس هپاتیت C در بین کارکنان مراقبت‌های بهداشتی در مصر شامل ۸۵۹ بیمار و دوازده بیزگی استفاده کرده و دو رویکرد بدون انتخاب بیزگی و انتخاب روبه‌جلوی متوالی<sup>۱۲</sup> را برای اصلاح مجموعه‌بیزگی‌ها مورد استفاده قرار دادند. علیزرگر و همکاران [۲۹] الگوریتم‌های یادگیری ماشین را روی مجموعه‌داده‌های موجود در NHANES<sup>۱۳</sup> و UCI بررسی کرده و الگوریتم‌های بردار ماشین پشتیبان و تقویت گرادیان شدید<sup>۱۴</sup> را به عنوان روش‌های پیش‌بینی بیماری‌های کبدی و هپاتیت C از روی داده‌های آزمایش خون پیشنهاد داده‌اند. بهاراتی و همکاران [۱۳] از مدل‌های طبقه‌بندی ماشین بردار پشتیبان، درخت تصمیم، رگرسیون ترازی و جنگل تصادفی با استفاده از انتخاب بیزگی و هم بدون آن برای پیش‌بینی ویروس هپاتیت C بهره گرفته‌اند.

در جدول (۱) کارایی مدل‌های یادگیری ماشین که برای پیش‌بینی بیماری‌های کبدی مورداً استفاده قرار گرفته‌اند، ارائه شده‌است. در این جدول بهترین کارایی مدل‌ها گزارش شده‌است. توجه به این نکته ضروری است که برخی از این روش‌ها، همانند مدل مطرح شده در مرجع [۳]، نتایج را تنها بر روی مجموعه‌داده آزمایشی بیان کرده و از ارزیابی مدل‌ها بر روی مجموعه‌داده آزمایشی خودداری کرده‌اند. بدیهی است که نتایج بر روی مجموعه‌داده‌های آزمایشی کمتر از مقادیر بیان شده در جدول (۱) خواهد بود. همان‌گونه که در این جدول مشاهده می‌شود، هنوز کارایی مدل‌ها از حالت ایده‌آل فاصله دارد و تلاش زیادی برای بهبود نتایج مورد نیاز است.

### ۳- مواد و روش‌ها

#### ۳-۱- مجموعه‌داده

جدول (۲) مشخصات آماری مجموعه‌داده مورد استفاده در این پژوهش را نشان می‌دهد. این مجموعه‌داده شامل ۶۱۵ رکورد است که در آن هر رکورد شامل دوازده بیزگی است که عبارت‌اند از: سن، جنسیت، آلبومین<sup>۱۵</sup>،

<sup>۱۱</sup> UCI machine learning repository

<sup>۱۲</sup> Sequential forward selection

<sup>۱۳</sup> National health and nutrition examination Survey

<sup>۱۴</sup> Extreme gradient boosting (XGB)

<sup>۱۵</sup> Albumin (ALB)

تصادفی را برای پیش‌بینی بیماری‌های کبدی و غفونت ویروس هپاتیت C پیاده‌سازی و از الگوریتم جنگل تصادفی به عنوان یک یادگیرنده ضعیف برای افزایش پایداری و دقت و در عین حال به کمترین حد رساندن بیش‌برازش استفاده شد. در مراجع [۱۲ و ۲۴]<sup>۱۶</sup> با هدف شناسایی عوامل مهم تشخیص بیماری کبد، الگوریتم‌های یادگیری ماشین را بر روی مجموعه‌ای از داده‌های جمع‌آوری شده از ۶۱۵ فرد مورد مطالعه قرار دادند. آن‌ها از تجسم داده‌ها و روش‌هایی مانند انتساب چندگانه به‌وسیله معادلات زنجیره‌ای برای مواجهه با داده‌های مفقود استفاده کردند و تحلیل مؤلفه‌های اصلی را برای کاهش ابعاد به کار بردن؛ همچنین رتبه‌بندی متغیرهای مهم حاصل از اندیس جینی را به‌وسیله تحلیل مؤلفه‌های اصلی مورد آزمایش قرار داده و الگوریتم‌های طبقه‌بندی دودویی از جمله شبکه‌های عصبی مصنوعی، جنگل‌های تصادفی و ماشین‌های بردار پشتیبان را برای تمایز بین نمونه‌های خون مبتلا به هپاتیت، فیروز و سیروز به کار بردن. هافمن و همکاران [۲۵]<sup>۱۷</sup> دو الگوریتم یادگیری ماشین مبتنی بر درخت تصمیم به همراه معیار درجه فیروز کبدی پیشرفت‌هه<sup>۱</sup>، که تولید خودکار درختان تصمیم‌گیری را با استفاده از داده‌های آزمایشگاهی تسهیل می‌کنند، مورد بررسی قرار دادند. چیکو و ژورمن [۲۶]<sup>۱۸</sup> سوابق الکترونیکی سلامت<sup>۲</sup> متعلق به ۵۴۰ فرد سالم و ۷۵ بیمار مبتلا به هپاتیت C را برای بررسی قابلیت طبقه‌بندی یادگیری ماشین، به‌ویژه جنگل تصادفی، در پیش‌بینی تشخیص را در نظر گرفتند. آن‌ها با شناسایی متغیرهای حیاتی نظیر آمینوترانسفراز<sup>۳</sup> (AST) و آلانین آمینوترانسفراز<sup>۴</sup> (ALT) با به کاربستن یک گروه اعتبارسنجی شامل ۱۲۳ بیمار مبتلا به هپاتیت C و سیروز، اهمیت این آنژیم‌ها را مورد تأیید قرار داده و با ارزیابی‌های به عمل آمده، نشان دادند که مدل یادگیری گروهی، از نسبت سنتی AST/ALT عملکرد بهتری دارد؛ و درنتیجه اطلاعات بالینی را بهبود بخشیده و مراقبت از بیمار را ارتقا می‌دهد.

در مرجع [۳]<sup>۱۹</sup>، یک روش پیش‌پردازش داده‌های تطبیقی ارائه شده‌است؛ بهطوری که عملکرد مدل‌های بنیادی یادگیری ماشین را از طریق روش‌هایی مانند پرکردن میانگین اختصاصی طبقه<sup>۵</sup>، حذف داده‌های پرت<sup>۶</sup>، نرمال‌سازی لگاریتمی<sup>۷</sup>، انتخاب بیزگی<sup>۸</sup>، مقیاس‌بندی بیزگی<sup>۹</sup> و تعادل داده‌ها<sup>۱۰</sup> بهبود می‌بخشد؛ همچنین آن‌ها برای تسهیل کاربرد

<sup>۱</sup> Enhanced liver fibrosis (ELF) score

<sup>۲</sup> Electronic health records

<sup>۳</sup> Aspartate aminotransferase

<sup>۴</sup> Alanine aminotransferase

<sup>۵</sup> Class specific mean imputation

<sup>۶</sup> Outlier rejection

<sup>۷</sup> Log normalization

<sup>۸</sup> Feature selection

<sup>۹</sup> Feature scaling

<sup>۱۰</sup> Data balancing

(جدول-۱): کارایی گزارش شده به وسیله روش های یادگیری ماشین برای پیش بینی بیماری های کبدی

(Table-1): Reported performance of machine learning methods for predicting liver diseases

صحت	مجموعه داده	مدل های مورد استفاده	مراجع	سال
RF: 0.9814	۶۱۵ بیمار با ۱۴ ویژگی	ANN, RF, SVM	[۲۴]	۲۰۲۱
SVM: 0.9823	۶۱۵ بیمار با ۱۴ ویژگی	ANN, RF, SVM	[۱۲]	۲۰۲۱
RF: 0.9990	۶۱۵ بیمار با ۱۱ ویژگی	MLP, RF, J48	[۲۷]	۲۰۲۱
RF: 0.971	۶۱۵ بیمار با ۱۱ ویژگی	RF, DT, LR	[۲۶]	۲۰۲۱
RF: 0.9729	۶۱۵ بیمار با ۱۲ ویژگی	SVM, NB, DT, RF, LR, KNN	[۳۰]	۲۰۲۱
DT: 0.9931	۶۱۵ بیمار با ۱۴ ویژگی	LR, KNN, DT, RF, SVM, ETC, ADA, NB	[۲۳]	۲۰۲۲
LR: 0.948	۶۱۵ بیمار با ۱۱ ویژگی	LR, RF, RPART, CTREE, XGB	[۱۵]	۲۰۲۲
SVM, XGB: 0.95	۶۱۵ بیمار با ۱۲ ویژگی	KNN, DT, ANN, SVM, LR, XGB	[۲۹]	۲۰۲۳
RF: 0.9488	۸۵۹ بیمار با ۱۲ ویژگی	NB, RF, KNN, LR	[۲۸]	۲۰۲۳
RF: 0.89	۹۹۷ بیمار با ۱۰ ویژگی	DT, SVM, LR, RF	[۱۳]	۲۰۲۴
RF: 0.8866	۱۵۵ بیمار با ۲۰ ویژگی	RST, KNN, LSVM, RBF SVM, DT, RF, NB	[۱۷]	۲۰۲۴
Ensemble LR: 0.9984	UCI ۶۱۵ بیمار با ۱۲ ویژگی	LR, SVM, RF, DT, XB, Ensemble LR, Ensemble XB, Ensemble RF	[۳]	۲۰۲۴

(جدول-۲): مشخصات مجموعه داده مورد ارزیابی

(Table-2): Characteristics of the data set being evaluated

معیار	۵۵	سن	جنسیت	ALB	ALT	۵۹۷	۶۱۴	۶۱۵	AST	BIL	CHE	CHOL	CREA	GGT	PROT	
تعداد	۶۱۵	۶۱۵														۶۱۴
میانگین	-	۴۷.۴۱	.۳۹	۴۱.۶۲	۲۸.۴۵	۳۴.۷۹	۱۱.۴۰	۸.۲۰	۵.۳۷	۸۱.۲۹	۳۹.۰۳	۷۲.۰۴				
انحراف معیار	-	۱۰.۰۶	.۴۹	۵.۷۸	۲۶.۰۳	۲۵.۴۷	۱۹.۶۷	۲.۲۱	۱.۱۳	۴۹.۷۶	۵۴.۶۶	۵.۴۰				
کمینه	۱	۱۹	.	۱۴.۹	۱۰.۶	۰.۹	۱۱.۳					۴۴.۸	۴.۵			
بیشینه	۵	۷۷	۱	۸۲.۲	۳۲۵.۳	۴۱۶.۶	۲۵۴	۱۶.۴۱	۹.۶۷	۱۰۷۹.۱	۶۵۰.۹	۹۰				

شکل (۱) نمودار پراکندگی ماتریسی را برای مجموعه داده مورد بحث نشان می دهد که با استفاده از کتابخانه Seaborn در پایتون ایجاد شده است. این نمودار همبستگی بین متغیرها در مجموعه داده را نشان می دهد. درایه های قطر اصلی، توزیع مقادیر هر متغیر را به صورت هیستوگرام نشان می دهد. درایه های زیر قطر اصلی نمودار پراکندگی جفت متغیرها را نشان می دهد. خط قرمز رنگ، خط رگرسیون خطی است که جهت گیری ارتباط بین متغیرها را نشان می دهد. درایه های بالای قطر اصلی، ضرایب همبستگی پیرسون بین جفت متغیرها را نشان می دهد. رنگ ها شدت و جهت همبستگی را نشان می دهند. ماتریس نشان می دهد که بیشترین همبستگی مثبت در بین دو متغیر Category و AST با مقدار ۶۵ است، در مقابل، بیشترین همبستگی منفی بین دو متغیر ALB و Category با مقدار -۰.۲۹ است.

آلکالین آمینوتранسفراز<sup>۱</sup>، آسپارتات آمینوتранسفراز<sup>۲</sup>، بیلی روبین<sup>۳</sup>، کولین استراز<sup>۴</sup>، کلسترول<sup>۵</sup>، کراتینین<sup>۶</sup>، گاما گلوتامین ترانسفراز<sup>۷</sup> و پروتئین<sup>۸</sup> .

داده ها به پنج طبقه اصلی تقسیم شده اند: اهدا کننده خون<sup>۹</sup>، اهدا کننده خون مشکوک<sup>۱۰</sup>، هپاتیت<sup>۱۱</sup>، فیبروز<sup>۱۲</sup> و سیروز<sup>۱۳</sup>. مجموعه داده مورد استفاده در نشانی زیر قابل دسترسی است:

<https://archive.ics.uci.edu/dataset/571/hcv+data>  
جدول (۳) توزیع داده ها در طبقه های مجموعه داده را نشان می دهد؛ همان گونه که در جدول مشاهده می شود، در مجموعه داده اصلی تعداد نمونه ها در هر طبقه برابر نیست و این عدم توازن می تواند بر تفسیر دقیق مدل تأثیر بگذارد.

<sup>۱</sup> Alanine aminotransferase (ALT)

<sup>۲</sup> Aspartate aminotransferase (AST)

<sup>۳</sup> Bilirubin (BIL)

<sup>۴</sup> Cholinesterase (CHE)

<sup>۵</sup> Cholesterol (CHOL)

<sup>۶</sup> Creatinine (CREA)

<sup>۷</sup> Gamma-glutamyl transferase (GGT)

<sup>۸</sup> Protein (PROT)

<sup>۹</sup> Blood donor

<sup>۱۰</sup> Suspect blood donor

<sup>۱۱</sup> Hepatitis

<sup>۱۲</sup> Fibrosis

<sup>۱۳</sup> Cirrhosis

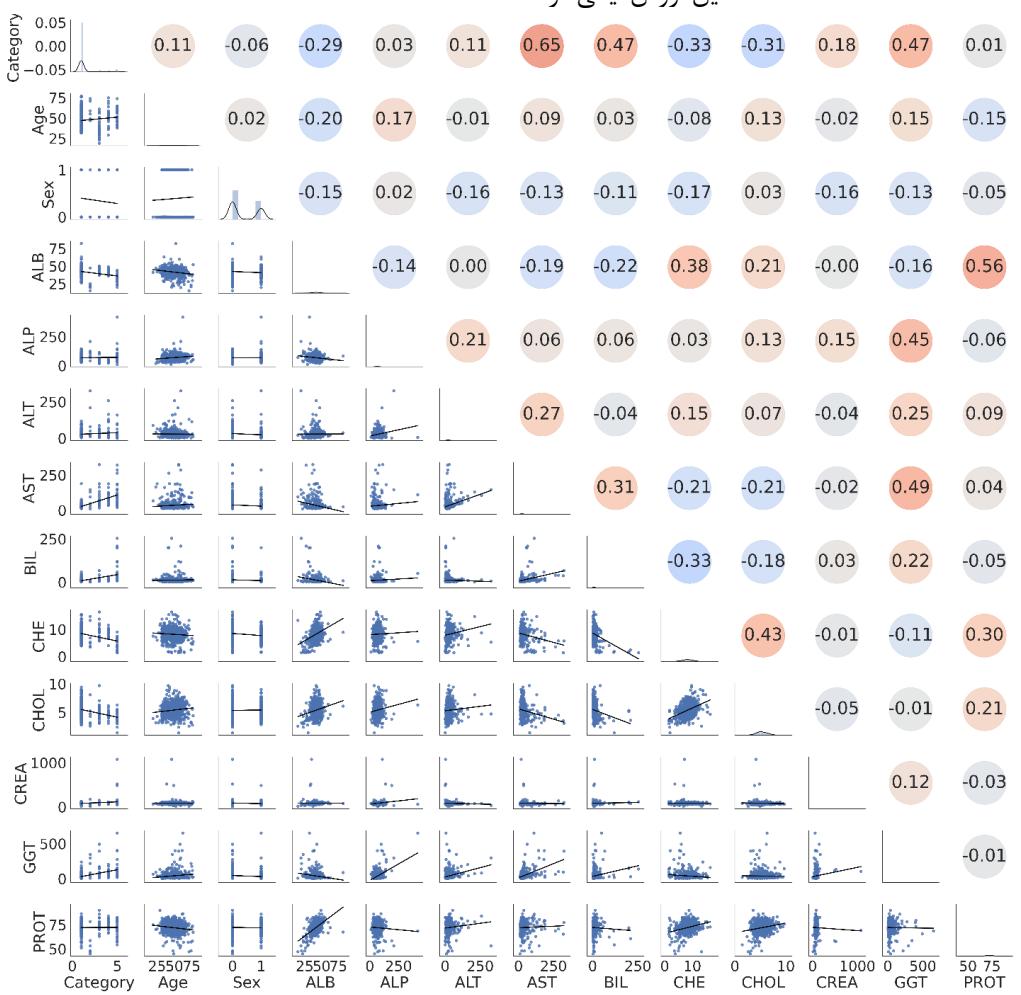
در مرحله پیش پردازش ابتدا به بررسی مقادیر میانگین و انحراف معیار ویژگی ها پرداخته شده است؛ همان گونه که در جدول (۲) مشاهده می شود، این مقادیر با یکدیگر اختلاف زیادی دارند. برای حل این مسئله از ماثول مقياس بندی



رهیافت‌های کارآمد برای مقابله با مشکل عدم توازن در طبقه‌ها است. در بسیاری از مسائل یادگیری ماشین، بهویژه در حوزه‌های پزشکی، تعداد نمونه‌های طبقه کمینه به طور قابل توجهی کمتر از طبقه بیشینه است. عدم توازن می‌تواند منجر به عملکرد ضعیف مدل‌ها شود؛ زیرا مدل‌های یادگیری ماشین بیشتر تمکن کنند و درنتیجه دقت پیش‌بینی برای طبقه کمینه کاهش می‌یابد.

استاندارد در پایتون استفاده شده است تا مقادیر رکوردهای مجموعه‌داده به طور مناسب پردازش شوند و تمام ویژگی‌های عددی در مقایسه قابل مقایسه قرار گیرند. این کار باعث می‌شود که هر ویژگی به طور مساوی در فرایند یادگیری مدل‌های یادگیری ماشین نقش داشته باشد.

مطابق جدول (۳)، در مجموعه‌داده مورد استفاده تعداد نمونه‌ها در هر طبقه برابر نیست و این عدم تعادل می‌تواند بر تفسیر دقت مدل تأثیر بگذارد؛ به همین دلیل، از روش SMOTE استفاده شده است. این روش یکی از



(شکل-1): ماتریس برآکنده متحیرها در مجموعه‌داده به همراه ضرائب همبستگی

(Figure-1): The dispersion matrix of variables in the data set along with correlation coefficients of the pre-processing phase on a sample web page

می‌شود. این فرایند به تولید نمونه‌های جدیدی منجر می‌شود که در فضای ویژگی در نزدیکی نمونه‌های موجود قرار دارند، اما به اندازه کافی متفاوت‌اند تا تنوع داده‌ها را افزایش دهند؛ همچنین داده‌های گم‌شده می‌توانند به دلایل مختلفی مانند خطا در جمع‌آوری داده‌ها یا عدم پاسخ‌گویی در نظرسنجی‌ها ایجاد شوند و وجود آن‌ها می‌تواند تأثیر قبل توجهی بر عملکرد مدل‌های یادگیری ماشین بگذارد. برای حل مشکل داده‌های گم‌شده از روش جایگزینی میانه<sup>۱</sup> استفاده شده است که در آن مقادیر گم‌شده هر حوزه با میانه مقادیر موجود

روش SMOTE به طور خاص با هدف افزایش تعداد نمونه‌های طبقه کمینه و بهبود توازن بین طبقه‌ها طراحی شده است؛ این روش به جای رونوشت برداری ساده از نمونه‌های موجود در طبقه کمینه، نمونه‌های جدیدی را به صورت مصنوعی تولید می‌کند. در الگوریتم SMOTE، ابتدا برای هر نمونه موجود در طبقه کمینه،  $k$  همسایه نزدیک، با استفاده از الگوریتم KNN شناسایی می‌شود؛ سپس برای تولید یک نمونه جدید، یک همسایه تصادفی از بین  $k$  همسایه انتخاب می‌شود و یک نقطه جدید در فضای ویژگی با استفاده از ترکیب خطی بین نمونه اصلی و همسایه انتخاب شده ایجاد

<sup>1</sup> Median

آموزش، این روش از مجموعه‌های از درختان برای پیش‌بینی هدف در مجموعه‌داده آزمایشی استفاده می‌کند و پیش‌بینی نهایی به عنوان مجموع وزنی خروجی‌های همه درختان محاسبه می‌شود.

تفاوت اصلی بین این روش تقویت گرادیان و تقویت گرادیان شدید در پیاده‌سازی و روش‌های بهینه‌سازی آن‌ها نهفته است؛ در حالی‌که هر دو روش از مجموعه‌های از درختان تصمیم‌برای بهبود دقت پیش‌بینی استفاده می‌کنند. روش تقویت گرادیان شدید به گونه‌ای طراحی شده است که کارآمدتر و مقیاس‌پذیرتر باشد. این روش ویژگی‌های پیشرفت‌های مانند منظم‌سازی برای جلوگیری از برآش بیش از حد، پردازش موازی برای محاسبات سریع‌تر و مدیریت پیچیده‌تر مقادیر از دست‌رفته را شامل می‌شود.

### ۳-۳-۲-طبقه‌بندی جنگل تصادفی

روش طبقه‌بندی جنگل تصادفی یک روش یادگیری مجموعه‌ای است که درخت‌های تصمیم‌گیری متعددی را در طول آموزش می‌سازد و از نتایج آن‌ها برای بهبود دقت پیش‌بینی استفاده می‌کند. در این روش از روش‌های بوت‌استرپینگ برای تولید درخت استفاده می‌شود که داده‌ها را دوباره نمونه‌برداری می‌کند تا تنوعی در بین درختان ایجاد کند و خطر بیش از حد برآش را کاهش دهد. روش جنگل تصادفی تفسیرهایی را در مورد اهمیت ویژگی‌هایی ارائه می‌دهد که تفسیر پذیری مدل‌های پیچیده را افزایش می‌دهد. ساختار آن نیز موازی‌پذیر است که کاربرد آن را برای مجموعه‌های داده بزرگ تسهیل می‌کند [۳۱]. درخت تصمیم یک درخت منفرد است که بر اساس تقسیم ویژگی‌ها تصمیم می‌گیرد؛ در حالی‌که جنگل تصادفی مجموعه‌ای از درختان تصمیم‌گیری است که همزمان کار می‌کند. درختان تصمیم‌گیری به‌ویژه با مجموعه‌داده‌های پیچیده مستعد بیش از حد برآش هستند، اما جنگل‌های تصادفی این مشکل را با میانگین‌گیری نتایج چند درخت کاهش می‌دهند که منجر به تعمیم بهتر می‌شود؛ همچنین، روش جنگل‌های تصادفی با انتخاب تصادفی ویژگی‌ها برای تقسیم در هر گره به کاهش واریانس و بهبود تنوع مدل کمک می‌کند که این امر بهبود عملکرد کلی مدل را به همراه دارد.

### ۳-۴-۳-درختان بی‌نهایت تصادفی

درختان بی‌نهایت تصادفی<sup>۳</sup> یک روش یادگیری ماشین برای دسته‌بندی است که از درخت‌های تصمیم‌گیری استفاده می‌کند و به عنوان یک جایگزین سریع‌تر برای روش جنگل تصادفی شناخته می‌شود. این الگوریتم مشابه جنگل تصادفی، چندین درخت تصمیم‌گیری ایجاد و پیش‌بینی‌های آن‌ها را ترکیب می‌کند. یکی از ویژگی‌های کلیدی این الگوریتم،

همان حوزه جایگزین می‌شود. روش میانه در مقابل داده‌های پرت<sup>۱</sup> مقاوم است؛ بنابراین انتخاب مناسبی برای جایگزینی مقادیر گم‌شده محسوب می‌شود.

(جدول-۳): توزیع داده‌ها در طبقه‌های مجموعه‌داده

(Table-3): Distribution of data points in the classes of benchmark dataset

نام طبقه	تعداد
اهداکننده خون	۵۳۳
اهداکننده خون مشکوک	۷
هپاتیت	۲۴
فیبروز	۲۱
سیروز	۳۰

## ۳-۳-روش‌های یادگیری ماشین

### ۳-۳-۱-رگرسیون تراابری

رگرسیون تراابری<sup>۲</sup> (LR) یک روش یادگیری نظارت شده است؛ این روش برخلاف نامش برای مسائل طبقه‌بندی دودویی استفاده می‌شود که در آن هدف پیش‌بینی احتمال تعلق یک ورودی داده شده به یک طبقه خاص است. روش رگرسیون تراابری به دلیل سادگی و اثربخشی در زمینه‌های مختلفی مانند مالی، بهداشت و درمان، بازاریابی و علوم اجتماعی کاربرد فراوانی دارد. در این روش متغیر وابسته دوقطبی است و متغیر مستقل می‌تواند دو جمله‌ای، ترتیبی، بازه‌ای یا سطح نسبت باشد. رگرسیون تراابری ابتدا برای مسائلی با دو نتیجه ممکن (برای مثال، بله/خیر، موافقیت/شکست) طراحی شده است؛ با این حال می‌توان آن را به مسائل طبقه‌بندی چندطبقه نیز تعمیم داد. این مدل ازتابع تراابری که به عنوان تابع سیگموئید نیز شناخته می‌شود، برای تبدیل خطی ترکیب ورودی‌ها به مقادیر احتمال استفاده می‌کند.

### ۳-۲-۲-تقویت گرادیان شدید

روش تقویت گرادیان شدید یک الگوریتم مقیاس‌پذیر و بهینه در یادگیری ماشین است که سرعت و عملکرد ماشین‌های تقویت گرادیان را بهبود بخشیده و در مسائل طبقه‌بندی و رتبه‌بندی کاربرد دارد. این روش از یک الگوریتم یادگیری مبتنی بر درخت تصمیم استفاده می‌کند و عملکرد مدل را با استفاده از محاسبات موازی و توزیع شده تسريع می‌کند. الگوریتم تقویت گرادیان شدید به‌طور مکرر درخت‌های تصمیم را اضافه می‌کند و هر درخت برای تصحیح خطاهای درختان قبلی آموزش داده می‌شود. این فرایند از گرادیان‌های تابع هزینه برای به‌کمینه‌رساندن خطاهای پیش‌بینی استفاده می‌کند و از روش‌های منظم‌سازی مانند لاسو و ریج برای جلوگیری از برآش بیش از حد استفاده می‌کند. پس از

<sup>1</sup> Outlier

<sup>2</sup> Logistic Regression

<sup>3</sup> Extra trees classifier



آنتروپی به عدم قطعیت موجود در یک مجموعه داده اشاره دارد و هدف آن کاهش آنتروپی از طریق تقسیم داده‌ها است؛ از سوی دیگر، شاخص جینی به احتمال اشتباه در پیش‌بینی طبقه‌ها اشاره داشته و هدف آن کمینه کردن این احتمال است. بدلیل ساختار درختی مدل درخت تصمیم، تفسیر این مدل‌ها آسان است و کاربران قادر خواهند بود مسیرهای تصمیم‌گیری را مشاهده کنند.

یکی از مزایای قابل توجه دسته‌بندی درخت تصمیم، توانایی آن در شناسایی روابط پیچیده درون داده‌ها بدون نیاز به مراحل پیش‌پردازش یا تبدیل گسترده است. درختان تصمیم می‌توانند برای داده‌های دسته‌ای و عددی به کار گرفته شوند و همچنین می‌توانند روابط بین ویژگی‌ها را به طور کارآمد مدل‌سازی کنند.

### ۳-۶-۳-روش یادگیری ابانته

شکل (۲) ساختار روش یادگیری ابانته (SML) را نشان می‌دهد. هدف از ارائه این مدل بهبود دقت پیش‌بینی با ترکیب پیش‌بینی‌های چندین مدل یادگیری متنوع است. مدل SML بر اساس مفهوم استفاده از یک فرامدل<sup>۲</sup> برای ترکیب پیش‌بینی‌های مدل‌های یادگیر پایه<sup>۳</sup> استوار است. فرامدل با یادگیری از پیش‌بینی‌های مدل‌های پایه پیش‌بینی نهایی را که از دقت بالایی برخوردار است انجام می‌دهد.

مراحل مدل پیشنهادی SML به صورت زیر است:

- ایجاد مدل‌های پایه: در این مرحله چهار مدل پایه

ساخته می‌شوند. این الگوریتم‌ها به دلیل کارایی بالای خود در مسائل دسته‌بندی و پیش‌بینی انتخاب شدند. این مدل‌ها به خوبی می‌توانند با داده‌های غیرخطی و پیچیده که در بیماری‌های کبدی وجود دارد، سازگار شوند؛ برای مثال درخت تصمیم و جنگل تصادفی به خوبی قادر به شناسایی الگوهای پیچیده در داده‌ها هستند و در عین حال قابلیت تفسیر نتایج را نیز فراهم می‌کنند؛ همچنین الگوریتم XGB به عنوان یک روش تقویت‌کننده، به طور خاص برای بهبود دقت پیش‌بینی طراحی شده است. این الگوریتم با استفاده از روش‌های بهینه‌سازی پیشرفت‌های می‌تواند به سرعت یاد بگیرد و دقت بالایی را در پیش‌بینی ارائه دهد.

- پیش‌بینی‌های مدل‌های پایه: هر کدام از مدل‌های پایه روی داده‌های آزمایشی اعمال شده و مقدار متغیر هدف را پیش‌بینی می‌کنند.

<sup>2</sup> Meta model

<sup>3</sup> Base models

انتخاب تصادفی ویژگی‌ها و نقاط تقسیم است. در مقایسه با جنگل تصادفی، درختان بی‌نهایت تصادفی به جای انتخاب بهترین تقسیم از یک زیرمجموعه تصادفی از ویژگی‌ها، ویژگی‌ها و نقاط تقسیم را به طور کامل تصادفی انتخاب می‌کنند. این رویکرد به افزایش سرعت الگوریتم کمک می‌کند و زمان آموزش را کاهش می‌دهد؛ علاوه بر این تصادفی بودن این روش به کاهش بیش‌پرازش کمک می‌کند و عملکرد مدل را بر روی داده‌های نادیده بهبود می‌بخشد، به ویژه در مقایسه با مدل‌هایی که از ویژگی‌های تصادفی استفاده نمی‌کنند؛ این روش با استفاده از نمونه‌برداری تصادفی با جایگزینی، چندین زیرمجموعه از داده‌ها را ایجاد می‌کند و هر یک از این زیرمجموعه‌ها به طور مستقل برای آموزش تعدادی از درختان استفاده می‌شود. درختان بی‌نهایت تصادفی دارای هایپرپارامترهایی هستند که می‌توانند بر عملکرد مدل تأثیر بگذارند، مانند تعداد درختان و تعداد ویژگی‌های تصادفی که در هر تقسیم استفاده می‌شود؛ درنهایت در این روش پیش‌بینی نهایی با میانگین‌گیری پیش‌بینی‌ها از تمامی درختان به دست می‌آید؛ در کل درختان بی‌نهایت تصادفی به دلیل سرعت و کارایی بالای خود ابزاری قدرتمند در یادگیری دسته‌های شناخته می‌شوند و می‌توانند در مسائل مختلف دسته‌بندی به کار گرفته شوند؛ همچنین درختان بی‌نهایت تصادفی به دلیل ساختار درختی خود می‌توانند به راحتی تفسیر شوند و به کاربران اجازه می‌دهند تا درک بهتری از فرایند تصمیم‌گیری داشته باشند.

### ۳-۵-۳-دسته‌بندی درخت تصمیم

دسته‌بندی درخت تصمیم<sup>۱</sup> یک مدل دسته‌بندی غیرخطی است که به طور گسترده‌ای در بسیاری از کاربردها مورد استفاده قرار می‌گیرد. این روش با تقسیم داده‌ها به زیرمجموعه‌های کوچک‌تر بر اساس ویژگی‌های خاص، ساختاری درختی ایجاد می‌کند. هر گره درخت نمایان گر یک ویژگی و هر شاخه نشان‌دهنده یک تصمیم یا نتیجه است که درنهایت به گره‌های برگ ختم می‌شود. در این مدل، مجموعه‌داده ورودی به طور مداوم به زیرمجموعه‌های کوچک‌تر بر اساس مقادیر ویژگی‌ها با استفاده از تقسیمات دوتایی بازگشته تقسیم می‌شود. گره‌های داخلی آزمایشی‌های ویژگی را توصیف می‌کنند و گره‌های برگ نتایج پیش‌بینی‌شده را بر اساس بیشترین طبقه‌ها یا مقادیر ابانته شده از نمونه‌های آموزشی موجود در آن زیرمجموعه‌ها نشان می‌دهند.

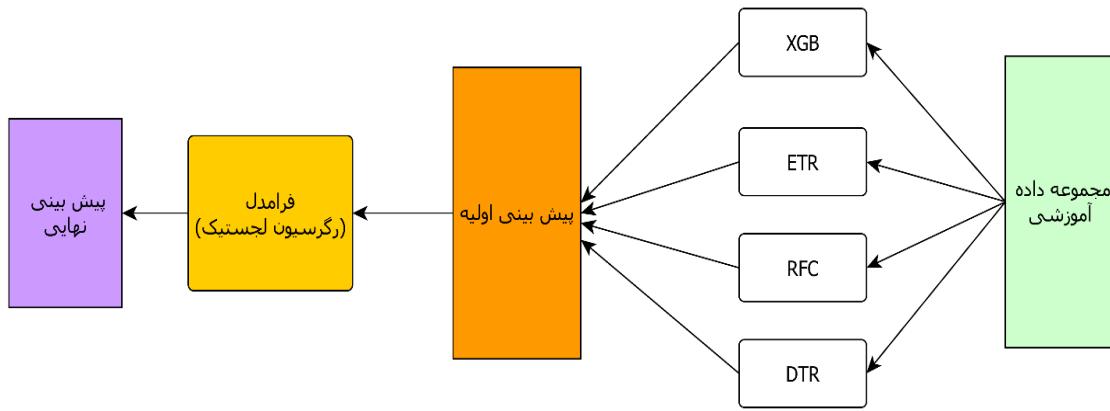
معیارهای مختلفی مانند آنتروپی و شاخص جینی در انتخاب ویژگی‌ها و تقسیم داده‌ها مورد استفاده قرار می‌گیرند.

<sup>1</sup> Decision tree classifier



**پیش‌بینی نهایی:** فرآمدل LR با استفاده از پیش‌بینی‌های مدل‌های پایه پیش‌بینی نهایی را ایجاد می‌کند.

- **ایجاد فرآمدل:** یک فرآمدل روی پیش‌بینی‌های تولیدشده بهوسیله مدل‌های پایه ساخته می‌شود. وظیفه فرآمدل یادگیری رابطه بین پیش‌بینی‌های مدل‌های پایه و خروجی واقعی است.



(شکل-۲): ساختار مدل پیشنهادی SML  
(Figure-2): Structure of the proposed SML model

بر حسب معیار دقت، مدل پیشنهادی SML، بهتریب با کسب مقادیر  $0.9982$  و  $0.9849$  بر روی مجموعه‌داده آموزشی و آزمایش بهترین نتایج را در قیاس با سایر مدل‌ها کسب کرده‌است. مقادیر دقت گزارش شده بهوسیله بیشتر مدل‌ها قبل قبول و حاکی از عملکرد مطلوب آن‌ها در تفکیک طبقه‌ها است. مقادیر بالای دقت گزارش شده نشان می‌دهد که مدل پیشنهادی در پیش‌بینی بیماری‌های کبدی بسیار دقیق عمل می‌کند و احتمال تشخیص اشتباه افراد سالم به عنوان بیمار بسیار کم است.

بر حسب معیار بازخوانی، مدل‌های SML، ET و DT بهتریب با نرخ بازخوانی  $0.994$  و  $0.998$  و  $0.9794$  بهترین نتایج را بر روی مجموعه‌داده آزمایشی و همچنین مدل SML بر روی مجموعه‌داده آموزشی با امتیاز  $0.9995$  بهترین نرخ بازخوانی را کسب کرده‌اند. کسب مقادیر بالای بازخوانی بهوسیله مدل پیشنهادی نشان از توانایی خوب آن در شناسایی نمونه‌های مثبت دارد.

بر حسب معیار F1 نیز بهترین نتایج برای مدل SML گزارش شده‌است. بر روی مجموعه‌داده آزمایشی، رتبه دوم و سوم متعلق به مدل‌های ET و DT است. نتایج نشان می‌دهد که مدل SML توازن مطلوبی بین دقت و بازخوانی برقرار کرده‌است. این موضوع نشان می‌دهد که مدل هم در تشخیص بیماری خوب عمل می‌کند و هم از تشخیص اشتباه افراد سالم به عنوان بیمار تا حد امکان جلوگیری می‌کند.

بر حسب معیار MAE، بهترین نتایج بهوسیله مدل ET کسب شده‌است که این مقدار برابر  $0.0032$  برای مجموعه‌داده آموزشی و  $0.024$  برای مجموعه‌داده آزمون است. مدل SML با کمی اختلاف در رده دوم قرار گرفته است.

## ۴-نتایج آزمایش‌ها و بحث

### ۴-۱-معیارهای ارزیابی

برای ارزیابی مدل‌ها و تحلیل نتایج از شش معیار کارایی استفاده شده است که عبارت‌اند از صحت<sup>۱</sup>، دقت<sup>۲</sup>، بازخوانی<sup>۳</sup> معیار F1، میانگین قدرمطلق خطأ<sup>۴</sup> (MAE) و جذر میانگین مربعات خطأ<sup>۵</sup> (RMSE) [۳۲].

### ۴-۲-نتایج آماری

جدول‌های (۴) و (۵) نتایج الگوریتم‌های یادگیری ماشین را بر روی مجموعه‌داده آموزشی و آزمایشی نشان می‌دهد. در تولید نتایج از روش اعتبارسنجی متقابل با  $k=5$  استفاده شده است تا از بروز بیش‌برازش در داده‌ها جلوگیری شود. با توجه به نتایج ارائه شده در جدول‌های (۴) و (۵) می‌توان موارد زیر را استنباط کرد.

بر حسب معیار صحت بهترین الگوریتم مدل SML است که بهتریب بر روی مجموعه‌داده‌های آزمایشی و آموزش نرخ صحت  $0.9991$  و  $0.9940$  را کسب کرده‌است. این موضوع نشان می‌دهد که این الگوریتم عملکرد مطلوبی در قیاس با سایر مدل‌ها دارد. الگوریتم ET جایگاه دوم را از نظر عملکرد ثبت کرده و پس از آن الگوریتم‌های DT و XGB در رتبه‌های بعدی قرار دارند. الگوریتم LR اگرچه مقدار صحت قبل قبولی کسب کرده‌است، اما در قیاس با سایر مدل‌ها در رتبه آخر قرار دارد.

<sup>1</sup> Accuracy

<sup>2</sup> Precision

<sup>3</sup> Recall

<sup>4</sup> Mean Absolute Error

<sup>5</sup> Root Mean Squared Error



(جدول-۴): نتایج مدل‌های یادگیری ماشین بر روی مجموعه‌داده آموزشی  
(Table-4): Results of machine learning models on the training dataset

مدل	SML	ETC	DTC	LR	RF	XGB	دقت	بازخوانی	MAE	RMSE
0.9991	0.9986	0.9760	0.9552	0.9941	0.9954	0.9932	0.9931	0.9931	0.125	0.1565
0.9991	0.9982	0.9794	0.9557	0.9941	0.9954	0.9932	0.9931	0.9931	0.152	0.1053
0.9991	0.9986	0.9760	0.9552	0.9941	0.9954	0.9932	0.9931	0.9931	0.156	0.2744
0.9991	0.9982	0.9794	0.9557	0.9941	0.9954	0.9932	0.9931	0.9931	0.156	0.2552
0.9991	0.9986	0.9760	0.9552	0.9941	0.9954	0.9932	0.9931	0.9931	0.152	0.0886
0.9991	0.9982	0.9794	0.9557	0.9941	0.9954	0.9932	0.9931	0.9931	0.152	0.0775

(جدول-۵): نتایج مدل‌های یادگیری ماشین بر روی مجموعه‌داده آزمایشی  
(Table-5): Results of machine learning models on the testing dataset

مدل	SML	ET	DT	LR	RF	XGB	دقت	بازخوانی	MAE	RMSE
0.994	0.984	0.976	0.9794	0.9568	0.9771	0.9716	0.97	0.97	0.05	0.3256
0.994	0.984	0.976	0.9794	0.9568	0.9771	0.9716	0.97	0.97	0.038	0.2449
0.994	0.984	0.976	0.9794	0.9568	0.9771	0.9716	0.97	0.97	0.066	0.3317
0.994	0.984	0.976	0.9794	0.9568	0.9771	0.9716	0.97	0.97	1.144	0.2552
0.994	0.984	0.976	0.9794	0.9568	0.9771	0.9716	0.97	0.97	0.024	0.1844
0.994	0.984	0.976	0.9794	0.9568	0.9771	0.9716	0.97	0.97	0.03	0.1789

«طبقهٔ واقعی» و محور افقی نشان‌دهنده «طبقهٔ پیش‌بینی شده» است. هر عدد در ماتریس درهم‌ریختگی، تعداد نمونه‌هایی را نشان می‌دهد که در طبقهٔ واقعی هدف بوده‌اند و به‌وسیله مدل در طبقهٔ پیش‌بینی شده یک ستون هدف دسته‌بندی شده‌اند. سلول‌های قطر اصلی ماتریس (از بالا سمت چپ به پایین سمت راست)، نشان‌دهنده دسته‌بندی‌های درست (ثبت واقعی)<sup>۱</sup> هستند. سلول‌های خارج از قطر اصلی نشان‌دهنده دسته‌بندی‌های نادرست (ثبت کاذب<sup>۲</sup> و منفی کاذب)<sup>۳</sup> هستند. تحلیل نتایج نشان می‌دهد که مدل SML در دسته‌بندی داده‌ها به‌خوبی عمل کرده‌است و نسبت به سایر مدل‌ها برتری دارد.

شکل (۵) منحنی‌های مشخصه عملکرد<sup>۴</sup> (ROC) را برای مدل‌های دسته‌بندی نشان می‌دهد. برای رسم و نمایش نمودار از کتابخانه matplotlib و برای محاسبات داده‌های مورد نیاز نمودار ROC از کتابخانه scikit-learn استفاده شده‌است. نمودار ROC به صورت گرافیکی نمایش می‌دهد که چقدر یک مدل دسته‌بندی عملکرد خوبی دارد و AUC (همان مساحت زیر نمودار) یک معیار عددی است که از نمودار ROC مشتق می‌شود و عملکرد کلی یک مدل را خلاصه می‌کند. در منحنی‌ها محور افقی نرخ مثبت کاذب و محور عمودی نرخ مثبت واقعی یا حساسیت را نشان می‌دهد. منحنی‌های ROC برای پنج طبقه در رنگ‌های مختلف نشان داده شده‌اند؛ همچنین دو منحنی

جایگاه سوم از منظر معیار MAE به مدل RF تعلق دارد. تحلیل مقادیر MAE نشان می‌دهد که تفاوت بین مشاهدات و پیش‌بینی مدل کمتر بوده و مدل در پیش‌بینی عملکرد خوبی دارد.

بر اساس معیار RMSE، بهترین نتایج متعلق به مدل پیشنهادی SML با مقادیر ۰.۷۵۵ و ۰.۱۷۸۹ به ترتیب برای مجموعه‌داده آموزشی و آزمایشی است. بعد از آن، مدل‌های ET و RF به ترتیب در ردیهای بعدی از منظر کارایی قرار دارند. مقادیر پایین RMSE نشان‌دهنده این است که مدل SML به‌طور متوسط دارای خطاهای کمتری در پیش‌بینی‌هاست و پیش‌بینی‌های مدل به مشاهدات واقعی نزدیک‌ترند.

شکل (۳) خطای پیش‌بینی طبقه را که به‌وسیله الگوریتم‌های پیش‌طبقه‌بند تولید شده‌است، نشان می‌دهد؛ در این نمودار، محور افقی، طبقهٔ واقعی، محور عمودی تعداد پیش‌بینی‌های یک طبقهٔ خاص را برای یک طبقهٔ واقعی و رنگ‌های مختلف، طبقه‌های پیش‌بینی شده مختلف را نشان می‌دهند. نتایج بیان‌کننده آن است که الگوریتم SML در پیش‌بینی طبقه‌ها به نحو مطلوبی عمل کرده‌است.

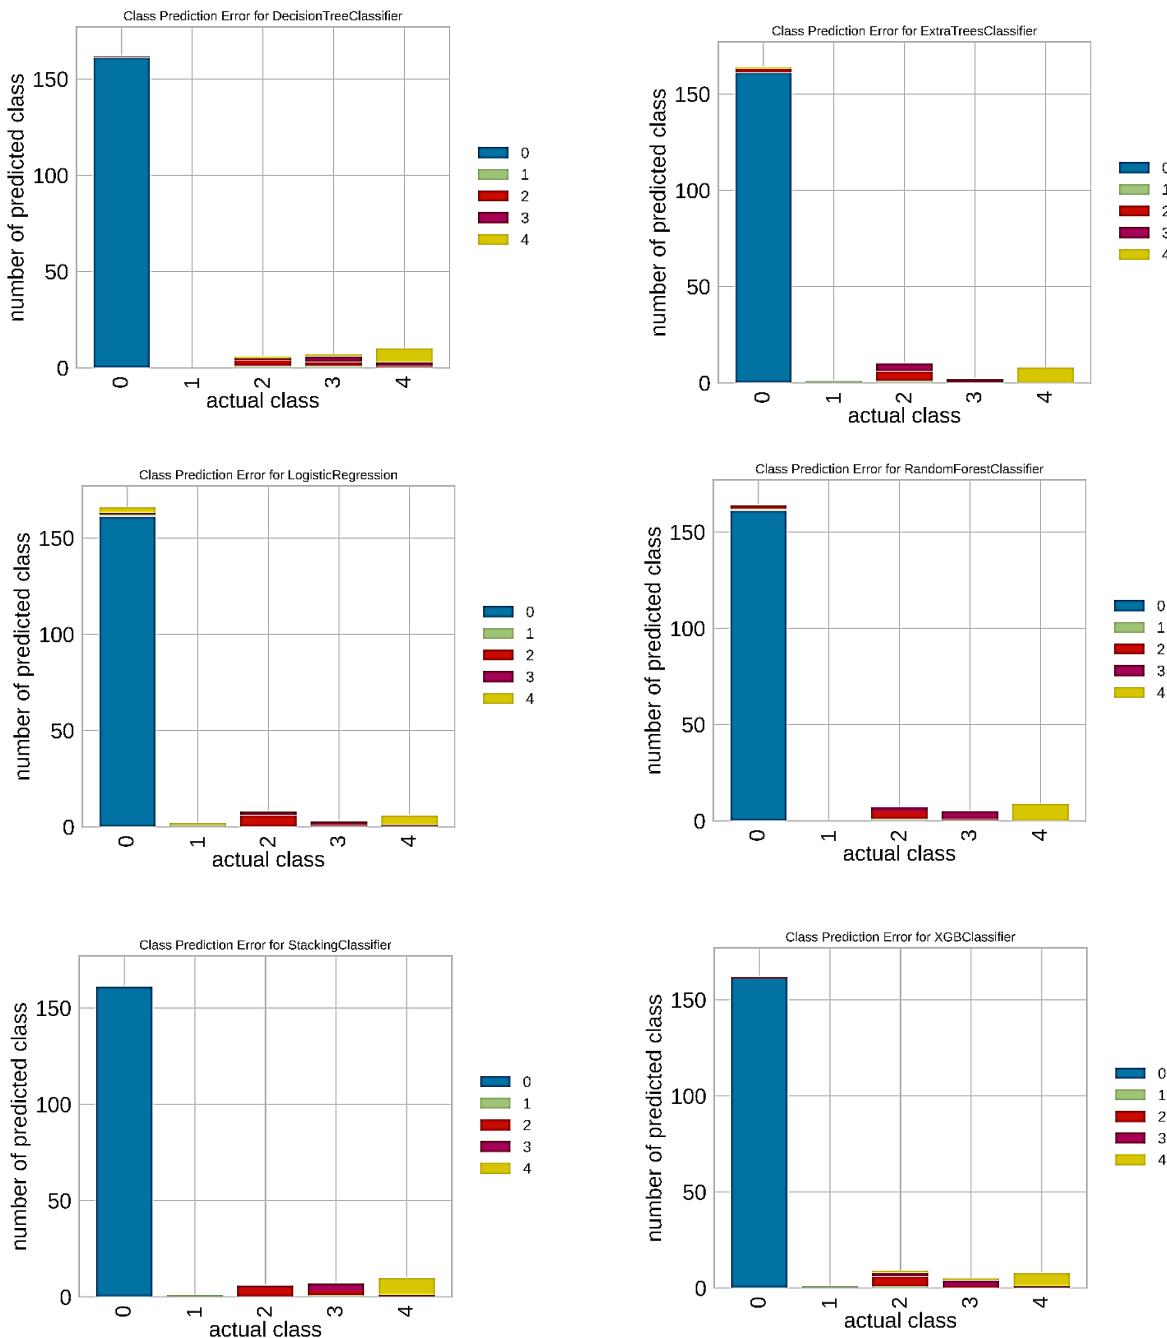
با اختصار می‌توان گفت که مدل SML بهترین عملکرد را در مقایسه با تمام مدل‌ها دارد و رتبه نخست را از منظر کارایی کلی کسب کرده‌است؛ همچنین رتبه دوم از نظر کارایی کلی به مدل ET تعلق دارد که می‌تواند به عنوان گزینه دوم برای پیش‌بینی در نظر گرفته شود.

شکل (۴) ماتریس درهم‌ریختگی را برای مدل‌های پیش‌بینی کننده نشان می‌دهد. محور عمودی نشان‌دهنده

<sup>1</sup> True Positives<sup>2</sup> False Positives<sup>3</sup> False Negatives<sup>4</sup> Receiver Operating Characteristic

می‌دهد و منحنی دوم میانگین عملکرد مدل را در سطح طبقه‌ها نشان می‌دهد؛ همچنین خط مورب نقطه‌چین در نمودارها نشان‌دهنده عملکرد یک دسته‌بند تصادفی (شانسی) است.

میانگین با عنوان macro- و micro-average ROC curve در نمودارها آمده است که منحنی average ROC curve نخست عملکرد کلی مدل را در سطح هر نمونه‌داده نشان



(شکل-۳): خطای پیش‌بینی طبقه‌ها به وسیله الگوریتم‌های پیش‌بینی کننده بر روی مجموعه‌داده آموزشی  
(Figure-3): Class prediction error by predictive algorithms on the training dataset

$$\beta_i = \int_0^1 TPR(FPR) d(FPR) \quad (2)$$

در این رابطه بالا TPR و FPR به ترتیب بیان‌کننده نرخ مثبت واقعی و نرخ مثبت کاذب است.

$$TPR = \frac{TP}{TP + FN} \quad (3)$$

رابطه ریاضی برای محاسبه  $\alpha_1^{ROC\_AUC}$  به صورت زیر است:

$$\alpha_1 = \frac{1}{C} \sum_{i=1}^C \beta_i \quad (1)$$

متغیر  $\beta_i$  بیان‌کننده مساحت زیر منحنی ROC است که به صورت زیر محاسبه شده است:



$$TPR = \frac{\sum_{i=1}^C TP_i}{\sum_{i=1}^C TP_i + \sum_{i=1}^C FN_i} \quad (6)$$

$$FPR = \frac{\sum_{i=1}^C FP_i}{\sum_{i=1}^C FP_i + \sum_{i=1}^C TN_i} \quad (7)$$

هر چه منحنی‌های ROC به گوشة بالا سمت چپ نمودار نزدیکتر باشند، حاکی از آن است که عملکرد مدل بهتر است. با تحلیل منحنی‌های ROC متوجه می‌شویم که مدل‌های دسته‌بند در بیشتر موارد مقادیر بالای AUC (نزدیک به یک) را کسب کرده و به خوبی بین طبقه‌های مختلف تمایز قائل شده‌اند. عملکرد مدل از سایر مدل‌ها بهتر است.

$$TPR = \frac{FP}{FP + TN} \quad (4)$$

در روابط بالا

:TP: تعداد نمونه‌های مثبت که درست پیش‌بینی شده‌اند.

:FN: تعداد نمونه‌های مثبت که اشتباه پیش‌بینی شده‌اند.

:FP: تعداد نمونه‌های منفی که اشتباه پیش‌بینی شده‌اند.

:TN: تعداد نمونه‌های منفی که درست پیش‌بینی شده‌اند.

رابطه ریاضی برای محاسبه  $\alpha_2$  به صورت زیر است:

$$\alpha_2 = \int_0^1 TPR(FPR)d(FPR) \quad (5)$$

DecisionTreeClassifier Confusion Matrix				
True Class	0	1	2	3
0	161	0	0	0
1	0	0	1	1
2	1	0	3	2
3	0	0	1	3
4	0	0	1	1
	0	1	2	3
Predicted Class	0	1	2	3

ExtraTreesClassifier Confusion Matrix				
True Class	0	1	2	3
0	161	0	0	0
1	0	1	1	0
2	2	0	5	0
3	0	0	4	2
4	1	0	0	8
	0	1	2	3
Predicted Class	0	1	2	3

LogisticRegression Confusion Matrix				
True Class	0	1	2	3
0	161	0	0	0
1	1	1	0	0
2	0	0	6	1
3	1	0	2	2
4	3	1	0	5
	0	1	2	3
Predicted Class	0	1	2	3

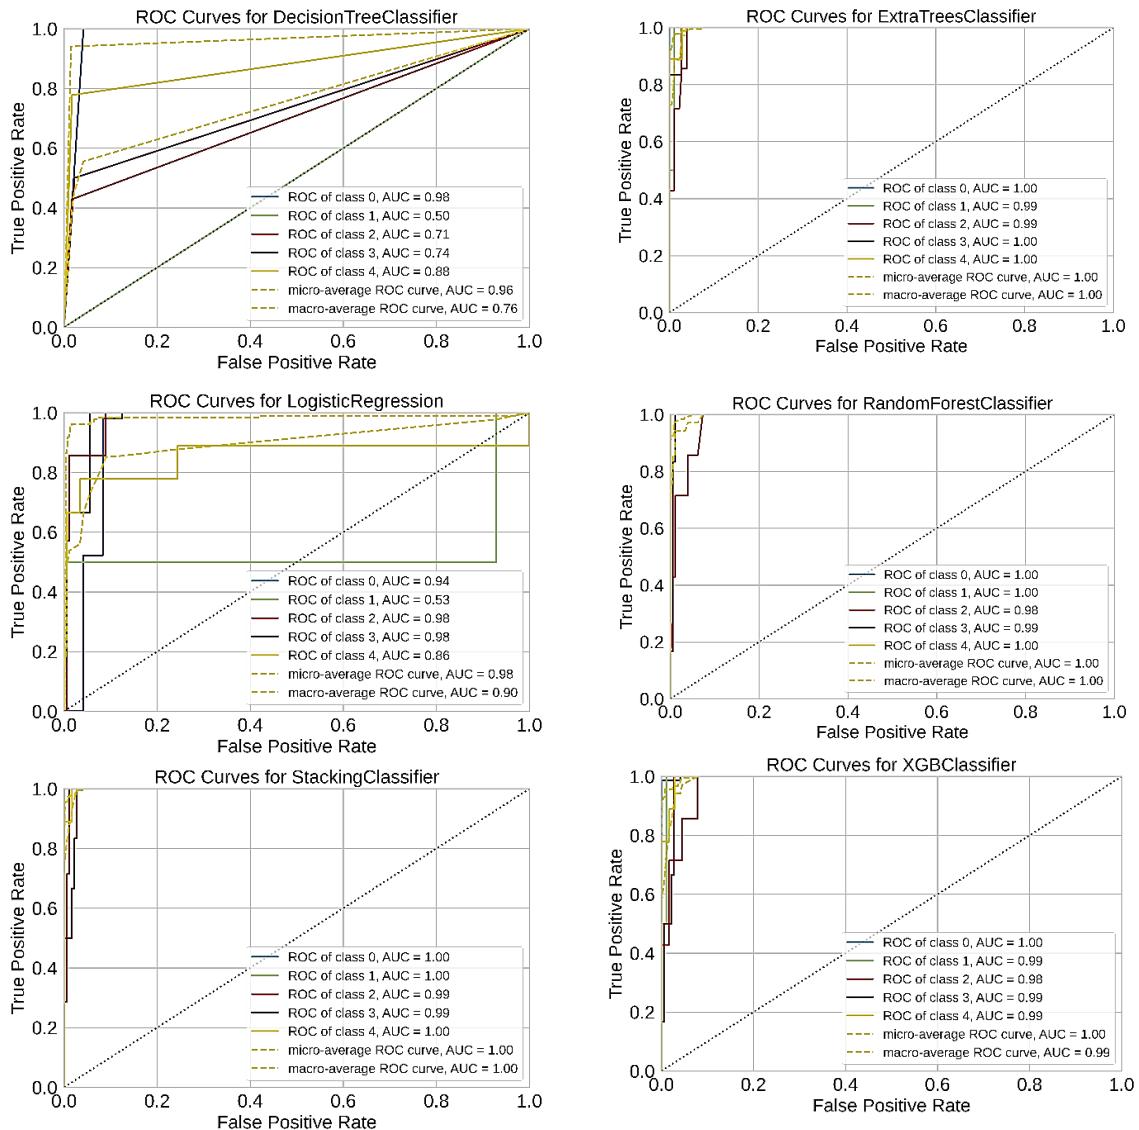
RandomForestClassifier Confusion Matrix				
True Class	0	1	2	3
0	161	0	0	0
1	1	0	1	0
2	2	0	4	1
3	0	0	2	4
4	0	0	0	9
	0	1	2	3
Predicted Class	0	1	2	3

StackingClassifier Confusion Matrix				
True Class	0	1	2	3
0	161	0	0	0
1	0	0	0	2
2	0	0	7	0
3	0	0	2	3
4	0	0	0	9
	0	1	2	3
Predicted Class	0	1	2	3

XGBClassifier Confusion Matrix				
True Class	0	1	2	3
0	161	0	0	0
1	0	1	1	0
2	1	0	5	1
3	0	0	2	3
4	0	0	1	7
	0	1	2	3
Predicted Class	0	1	2	3

(شکل-۴): ماتریس درهم ریختگی تولیدشده به وسیله الگوریتم‌های پیش‌بینی کننده

(Figure-4): Confusion matrix generated by predictive algorithms

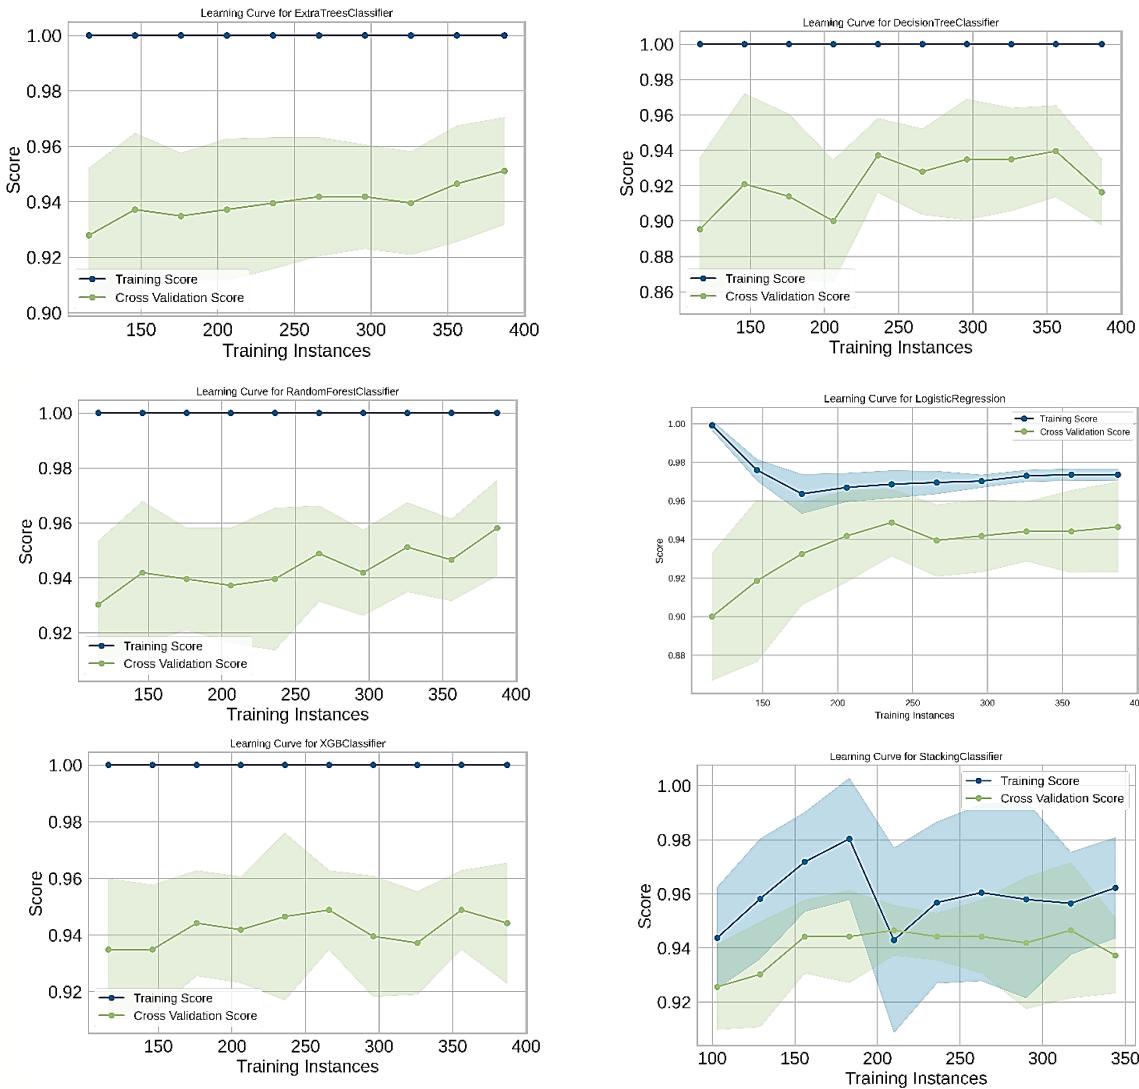


(شکل-۵): منحنی های مشخصه عملکرد برای مدل های یادگیری ماشین بر روی مجموعه داده آزمایش / آزمایشی  
 (Figure-5): Receiver Operating Characteristic curves for machine learning models on the test dataset

برای تعمیم به داده های دیده نشده است. در نمودارهای مدل های DT، RF، ET و XGB امتیاز آموزش اعتبر سنجی متقابل با امتیاز آموزشی فاصله دارد که نشان می دهد این مدل ها با خطر بیش برازش مواجه اند. این موضوع در جدول های (۴) و (۵) قابل مشاهده است که بر روی داده های آزمایش / آزمایشی، کارایی این مدل ها کمتر از مدل SML است. نمودار یادگیری برای مدل های SML و LR نشان می دهد که تعادل مناسبی بین نمره آموزشی و نمره اعتبر سنجی فراهم می کند. در نمودار مدل SML امتیاز آموزشی و اعتبر سنجی بسیار نزدیک به یکدیگرند که نشان می دهد مشکل بیش برازش در داده های آموزشی وجود ندارد. این موضوع به ما اطمینان می دهد که مدل می تواند به خوبی به داده های دیده نشده پاسخ دهد. نمودارها نشان می دهند که امتیاز اعتبر سنجی با افزایش تعداد نمونه ها بهبود می یابد. این نشان می دهد که افزودن داده های بیشتر به مدل ها به بهبود عملکرد و عملکرد پیش بینی کمک می کند.

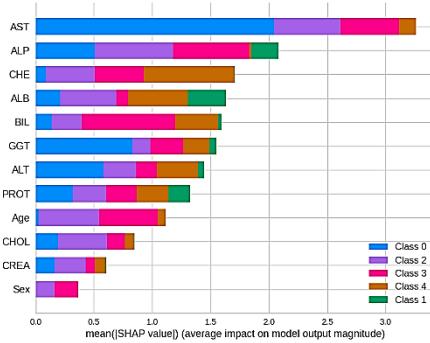
شکل (۶) نمودار مرز تصمیم را برای روش های یادگیری ماشین نشان می دهد. برای رسم نمودارها از دو ویژگی سن و جنسیت استفاده شده است. نتایج نشان می دهد که مدل های یادگیری ماشین در تفکیک داده های طبقه بندی شده کارایی قابل قبولی کسب کرده و نقاط داده در طبقه های مختلف به خوبی در نواحی مختلف تفکیک شده اند.

شکل (۷) منحنی یادگیری مدل ها را در پیش بینی طبقه داده ها نشان می دهد. دو خط در نمودارها وجود دارد که امتیاز آموزشی و امتیاز اعتبر سنجی را برای مدل های مختلف نشان می دهد. امتیاز آموزشی نشان دهنده دقت مدل بر روی داده های آموزشی است. در نمودار های DT، RF، ET و XGB امتیاز آموزش نزدیک به یک است که نشان می دهد این مدل ها می توانند به خوبی داده های آموزشی را یاد گرفته و برازش کنند، اما با خطر بیش برازش بر روی داده های آموزشی مواجه اند. امتیاز اعتبر سنجی متقابل نشان دهنده دقت مدل در داده های اعتبر سنجی است، که بیان کننده توانایی مدل ها



(شکل-۷): منحنی یادگیری مدل‌ها بر روی مجموعه‌داده آموزشی  
(Figure-7): Learning curve of models on the training dataset

است. تحلیل نمودار نشان می‌دهد که AST به عنوان تأثیرگذارترین ویژگی در بین سایر ویژگی‌ها مطرح است، بهویژه در طبقه صفر و چهار این تأثیر بیشتر است. ویژگی ALP بیشترین تأثیر را در طبقه صفر و دو دارد. ویژگی‌های CHE، BIL و ALB تأثیر زیادی در پیش‌بینی‌ها دارند، اگر چه تأثیر آن‌ها از AST و ALP کمتر است.



(شکل-۸): نمودار SHAP بر اساس خروجی مدل XGB بر روی مجموعه‌داده آموزشی  
(Figure-8): SHAP chart based on the XGB model on the training dataset

شکل (۸) اهمیت نسبی ویژگی‌ها را در پیش‌بینی مدل بر اساس نمودار توضیحات افزونی شپلی<sup>۱</sup> (SHAP) نشان می‌دهد. این نمودار اهمیت ویژگی‌ها را در یک مدل یادگیری ماشین نشان می‌دهد؛ به عبارت دیگر این نمودار نشان می‌دهد که کدام ویژگی‌ها در پیش‌بینی‌های مدل، بیشترین تأثیر را داشته‌اند. در شکل (۷)، نتایج بر اساس خروجی مدل XGB رسم شده‌است. محور افقی در نمودار، میانگین قدر مطلق مقادیر SHAP را برای هر ویژگی نشان می‌دهد؛ هر چه این مقدار بیشتر باشد، نشان‌دهنده تأثیر بیشتر (میزان اهمیت) آن ویژگی در پیش‌بینی‌های مدل است. این محور نشان می‌دهد تأثیر ویژگی به طور میانگین چه اندازه در خروجی مدل تغییر ایجاد می‌کند. محور عمودی فهرستی از ویژگی‌های ورودی مدل را به ترتیب اهمیت نشان می‌دهد. ویژگی‌هایی که بالاتر قرار دارند، تأثیر بیشتری بر خروجی مدل دارند. هر کدام از رنگ‌ها در نمودار بیان‌کننده یکی از طبقه‌های خروجی مدل است. طول هر مستطیل رنگ نیز بیان‌کننده میانگین تأثیر آن ویژگی بر روی پیش‌بینی‌های مربوط به هر طبقه

<sup>۱</sup> SHapley Additive exPlanations

(جدول-۶): مقایسه مدل پیشنهادی SML با سایر مدل‌های مطرح بر روی مجموعه داده آزمایش/آزمایشی  
(Table-6): Comparison of the proposed SML model with other proposed models on the testing dataset

مدل	موجع	صحت	دقت	بازخوانی	F1	MAE	RMSE
SVM	[۲۹]	۰.۹۵۰۰	۰.۹۶۰۰	۰.۹۴۰۰	۰.۹۵۰۰	---	---
RFC	[۱۷]	۰.۸۸۶۶	۰.۷۴۴۶	۰.۷۵۱۷	۰.۷۴۸۱	---	۰.۲۱۸
HGBoost	[۶]	۰.۸۳۴۳	۰.۸۳۰۰	۰.۸۴۰۰	۰.۸۴۰۰	---	۰.۴۳۰۸
Ensemble learning	[۳]	۰.۹۸۲۰	۰.۹۸۱۲	۰.۹۷۸۰	۰.۹۸۰۰	۰.۰۳۶۰	۰.۲۰۴۹
SML	--	۰.۹۹۴۰	۰.۹۹۴۲	۰.۹۹۴۰	۰.۹۸۸۰	۰.۰۳۰۰	۰.۱۷۸۹

ترکیب مدل‌های یادگیری پایه و فرامدل ارائه شد. تحلیل نتایج آزمایش‌ها نشان می‌دهد که روش پیشنهادی در مقایسه با سایر مدل‌های یادگیری ماشین و داده‌کاوی از کارایی بالایی برخوردار است. تحلیل منحنی یادگیری برای مدل‌های مختلف نشان داد که مدل پیشنهادی SML مشکل بیش‌بازش را به خوبی حل کرده و امتیاز آموزش و اعتبارسنجی مطلوبی تولید کرده است. مطابق دانش نویسندگان مقاله، روش پیشنهادی بالاترین دقت را در بین تمام روش‌های موجود در ادبیات موضوع کسب کرده است. یکی از کارهای آینده، ارزیابی روش پیشنهادی بر روی مجموعه داده‌های متنوع با مقیاس بزرگ است تا محدودیت‌ها و نقاط قوت روش پیشنهادی بهتر مشخص شود؛ همچنین استفاده از مدل‌های یادگیری مختلف در لایه‌های مدل SML می‌تواند به بهبود هر چه بیشتر کارایی آن کمک کند.

## 7-References

- C. Gan, Y. Yuan, H. Shen, et al., "Liver diseases: epidemiology, causes, trends and predictions," *Signal Transduction and Targeted Therapy*, vol. 10, no. 33, 2025, doi: 10.1038/s41392-024-02072-z.
- S. K. Asrani, H. Devarbhavi, J. Eaton, P. S. K.-J. of hepatology, and undefined 2019, "Burden of liver diseases in the world," *Elsevier*, 2019, doi: 10.1016/j.jhep.2018.09.014.
- A. Al Ahad, B. Das, M. R. Khan, N. Saha, A. Zahid, and M. Ahmad, "Multiclass liver disease prediction with adaptive data preprocessing and ensemble modeling," *Results in Engineering*, vol. 22, p. 102059, 2024.
- R. K. Sterling et al., "AASLD Practice Guideline on blood-based noninvasive liver disease assessment of hepatic fibrosis and steatosis," *Hepatology*, 2024, doi: 10.1097/HEP.0000000000000845.
- S. Aminizadeh et al., "Opportunities and challenges of artificial intelligence and distributed systems to improve the quality of healthcare service," *Artif Intell Med*, vol. 149, Mar. 2024, doi: 10.1016/J.ARTMED.2024.102779.
- P. Theerthagiri, "Liver disease classification using histogram-based gradient boosting classification tree with feature selection algorithm," *Biomed Signal Process*

## ۷-مراجع

## ۵-مقایسه با روش‌های مطرح

مدل پیشنهادی SML با چندین مدل لبّه دانشی در ادبیات موضوع بر اساس معیارهای کارایی مقایسه شده است؛ این روش‌ها عبارت‌اند از ماشین بردار پشتیبان (SVM) [۲۹]، طبقه‌بند جنگل تصادفی (RFC) [۱۷]، درخت طبقه‌بندی افزایش گرادیان مبتنی بر هیستوگرام (HGBoost) [۶] و یادگیری جمعی [۳].

جدول (۶) نتایج کسب شده به وسیله مدل پیشنهادی و سایر مدل‌های همتا را بر حسب معیارهای کارایی مقایسه می‌کند. نتایج برتری مدل SML را در قیاس با سایر روش‌های همتا نشان می‌دهد. با توجه به نتایج گزارش شده در جدول (۶)، مدل پیشنهادی SML در معیار صحت نسبت به دیگر مدل‌ها برتری دارد و نشان‌دهنده این است که درصد پیش‌بینی‌های صحیح این مدل به‌طور قابل توجهی بیشتر از سایرین است. این مدل در بین تمامی مدل‌های مورد مقایسه بهترین عملکرد را از نظر دقت کسب کرده است؛ به عبارت دیگر SML در شناسایی موارد مثبت واقعی و کاهش خطاهای مثبت کاذب بسیار موفق عمل کرده است؛ همچنین از آنجا که مدل SML توانسته است نمونه‌های مثبت بیشتری را شناسایی کند و تعداد بسیار کمی از منفی‌های کاذب را گزارش دهد، نرخ بازخوانی مطلوبی نسبت به سایر مدل‌ها دارد؛ علاوه براین، مدل پیشنهادی تعادل مناسبی بین دقت و بازخوانی برقرار کرده که این امر در نرخ بالای F1 به‌وضوح مشهود است. پیش‌بینی‌های مدل SML به مقادیر واقعی بسیار نزدیک بوده و به همین دلیل این مدل کمترین مقادیر را بر اساس معیارهای MAE و RMSE نسبت به سایر مدل‌ها کسب کرده است. برتری مدل پیشنهادی SML آن را به عنوان یک روش قابل انکا در زمینه پیش‌بینی بیماری‌های کبدی مطرح می‌کند.

## ۶-نتیجه‌گیری

در این پژوهش مسئله پیش‌بینی بیماری‌های کبدی بررسی شده و روش یادگیری ماشین انباشته (SML) مبتنی بر

<sup>۱</sup> Ensemble learning

- [16] I. Trulson, S. Holdenrieder, and G. Hoffmann, "Using machine learning techniques for exploration and classification of laboratory data," *Journal of Laboratory Medicine*, vol. 48, no. 5, pp. 203–214, 2024.
- [17] K. N. Singh and J. K. Mantri, "A clinical decision support system using rough set theory and machine learning for disease prediction," *Intelligent Medicine*, vol. 4, no. 3, pp. 200–208, Aug. 2024, doi: 10.1016/J.IMED.2023.08.002.
- [18] H. Kaur, H. S. Pannu, and A. K. Malhi, "A Systematic Review on Imbalanced Data Challenges in Machine Learning," *ACM Computing Surveys (CSUR)*, vol. 52, no. 4, Aug. 2019, doi: 10.1145/3343440.
- [19] T.-H. S. Li, H.-J. Chiu, and P.-H. Kuo, "Hepatitis C virus detection model by using random forest, logistic-regression and ABC algorithm," *IEEE Access*, vol. 10, pp. 91045–91058, 2022.
- [20] M. M. Ershadi and A. Seifi, "Applications of dynamic feature selection and clustering methods to medical diagnosis," *Appl Soft Comput*, vol. 126, p. 109293, Sep. 2022, doi: 10.1016/J.ASOC.2022.109293.
- [21] M. Y. Shams, E. S. M. El-kenawy, A. Ibrahim, and A. M. Elshewey, "A hybrid dipper throated optimization algorithm and particle swarm optimization (DTPSO) model for hepatocellular carcinoma (HCC) prediction," *Biomed Signal Process Control*, vol. 85, p. 104908, Aug. 2023, doi: 10.1016/J.BSPC.2023.104908.
- [22] J. S. Sartakhti, M. H. Zangooei, and K. Mozafari, "Hepatitis disease diagnosis using a novel hybrid method based on support vector machine and simulated annealing (SVM-SA)," *Comput Methods Programs Biomed*, vol. 108, no. 2, pp. 570–579, Nov. 2012, doi: 10.1016/J.CMPB.2011.08.003.
- [23] M. Yağanoğlu, "Hepatitis C virus data analysis and prediction using machine learning," *Data Knowl Eng*, vol. 142, p. 102087, Nov. 2022, doi: 10.1016/J.DATATAK.2022.102087.
- [24] F. Mostafa, E. Hasan, M. Williamson, and H. Khan, "Statistical machine learning approaches to liver disease prediction," *Livers*, vol. 1, no. 4, pp. 294–312, 2021.
- [25] G. Hoffmann, A. Bietenbeck, R. Lichtenhagen, and F. Klawonn, "Using machine learning techniques to generate laboratory diagnostic pathways—a case study," *J Lab Precis Med*, vol. 3, no. 6, 2018.
- [26] D. Chicco and G. Jurman, "An ensemble learning approach for enhanced classification of patients with hepatitis and cirrhosis," *IEEE Access*, vol. 9, pp. 24485–24498, 2021.
- [27] A. Orooji and F. Kermani, "Machine learning based methods for handling imbalanced data in hepatitis diagnosis," *Frontiers in Health Informatics*, vol. 10, no. 1, p. 57, 2021.
- [28] H. Mamdouh Farghaly, M. Y. Shams, and T. Abd El-Hafeez, "Hepatitis C Virus prediction based on machine learning framework: a real-world case study in Egypt," *Knowl Inf Syst*, vol. 65, no. 6, pp. 2595–2617, Jun. 2023, doi: 10.1007/S10115-023-01851-4/TABLES/7.
- [7] مجدر، موسی، پروین، حمید، نجاتیان، صمد، باقری فرد، کرم الله، «ترکیب یک روش خوشه‌بندی تجمعی و یک معیار شباخت جدید برای مدل‌سازی رفتار و راثتی بیماری‌ها»، *فصلنامه پردازش عالم و ماده‌ها*، دوره ۱۸، شماره ۲، ص ۹۷-۱۱۴. [۱۴۰۰]
- [7] M. Mojarrad, H. Parvin, S. Nejatiyan, and K. A. Bagheri Fard, "Combining an Ensemble Clustering Method and a New Similarity Criterion for Modeling the Hereditary Behavior of Diseases," *Signal and Data Processing*, vol. 18, no. 2, pp. 97–114, Oct. 2021, doi: 10.52547/JSDP.18.2.97.
- [8] امامی، نسیبه، حسنی، زینب، «پیش‌بینی و تعیین عوامل مؤثر بر بقای پنج ساله کلیه پیوندی در داده‌های نامتوان با رویکرد فرالبتکاری و یادگیری ماشین»، *فصلنامه پردازش عالم و ماده‌ها*، دوره ۱۵، شماره ۴، ص ۸۵-۹۴. [۱۳۹۷]
- [8] N. Emami and Z. Hassani, "Prediction and determining the effective factors on the survival transplanted kidney for five-year in imbalanced data by the meta-heuristic approach and machine learning," *Signal and Data Processing*, vol. 15, pp. 85–94, 2019, doi: 10.29252/JSDP.15.4.85.
- [9] S. Hashem *et al.*, "Machine Learning Prediction Models for Diagnosing Hepatocellular Carcinoma with HCV-related Chronic Liver Disease," *Comput Methods Programs Biomed*, vol. 196, p. 105551, Nov. 2020, doi: 10.1016/J.CMPB.2020.105551.
- [10] K. Moulaei, H. Sharifi, K. Bahaaeinbeigy, A. A. Haghdoost, and N. Nasiri, "Machine learning for prediction of viral hepatitis: A systematic review and meta-analysis," *Int J Med Inform*, vol. 179, p. 105243, Nov. 2023, doi: 10.1016/J.IJMEDINF.2023.105243.
- [11] D. A. Jadhav, "An enhanced and secured predictive model of Ada-Boost and Random-Forest techniques in HCV detections," *Mater Today Proc*, vol. 51, pp. 186–195, Jan. 2022, doi: 10.1016/J.MATPR.2021.05.071.
- [12] F. B. Mostafa and M. E. Hasan, "Machine Learning Approaches for Inferring Liver Diseases and Detecting Blood Donors from Medical Diagnosis," *medRxiv*, Apr. 2021, doi: 10.1101/2021.04.26.21256121.
- [13] P. T. Bharathi, S. N. Bindu, S. G. Deepthi, H. U. Gunakeerthi, and K. U. Harshitha, "AI based solution for Predicting Hepatitis C Virus from Blood Samples," *International Conference on Smart Systems for Applications in Electrical Sciences, ICSSES 2024*, 2024, doi: 10.1109/ICSSES62373.2024.10561391.
- [14] M. Cedolin, M. E. Genevois, and Z. Canbulat, "Hepatitis C Diagnosis Using Computational Intelligence Techniques," *Lecture Notes in Networks and Systems*, vol. 1090 LNNS, pp. 29–36, 2024, doi: 10.1007/978-3-031-67192-0\_4.
- [15] M. Arif, M. A. Aslam, H. U. Rehman, M. Abbas, and S. Bukhari, "Laboratory Diagnostic Pathways Using Machine Learning," *VFAST Transactions on Software Engineering*, vol. 10, no. 1, pp. 78–85, Mar. 2022, doi: 10.21015/VTSE.V10I1.826.



حجت امامی دانشآموخته رشته مهندسی کامپیوتر گرایش هوش مصنوعی است. او دانشیار گروه مهندسی کامپیوتر دانشگاه بناب است. زمینه‌های پژوهشی وی شامل داده‌کاوی، یادگیری ماشین، سیستم‌های چندعاملی، الگوریتم‌های اکتشافی و فراکتشافی، هوش جمعی و کاربردهای آن است. هم‌اکنون او در زمینه استفاده از یادگیری ماشین در حوزه مدیریت ترافیک هوایی، تشخیص بیماری در حوزه پزشکی و جایابی گره‌ها در شبکه‌های نوری کار پژوهشی خود را ادامه می‌دهد.

نشانی رایانامه ایشان عبارت است از:

emami@ubonab.ac.ir

[29] A. Alizargar, Y. L. Chang, and T. H. Tan, "Performance Comparison of Machine Learning Approaches on Hepatitis C Prediction Employing Data Mining Techniques," *Bioengineering*, vol. 10, no. 4, p. 481, Apr. 2023, doi: 10.3390/BIOENG INEERING10040481/S1.

[30] R. Safdari, A. Deghatipour, M. Gholamzadeh, and K. Maghooli, "Applying data mining techniques to classify patients with suspected hepatitis C virus infection," *Intelligent Medicine*, vol. 2, no. 4, pp. 193–198, Nov. 2022, doi: 10.1016/J.IMED.2021.12.003.

[31] P. A. A. Resende and A. C. Drummond, "A Survey of Random Forest Based Methods for Intrusion Detection Systems," *ACM Computing Surveys (CSUR)*, vol. 51, no. 3, May 2018, doi: 10.1145/3178582.

[32] D. M. W. Powers, "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation," *Journal of Machine Learning Technologies*, vol. 2, no. 1, pp. 37–63, 2011.



بابک آذرنویید دانشآموخته رشته ریاضی کاربردی و هم‌اکنون استادیار گروه ریاضی و علوم کامپیوتر دانشگاه بناب است. زمینه‌های پژوهشی وی شامل روش‌های عددی حل معادلات دیفرانسیل، آنالیز عددی، یادگیری ماشین و کاربردهای آن‌هاست. در حال حاضر، وی در زمینه استفاده از یادگیری ماشین برای تشخیص بیماری در حوزه پزشکی و همچنین روش‌های عددی و فراابتکاری در حل معادلات دیفرانسیل به فعالیت‌های پژوهشی خود ادامه می‌دهد.

نشانی رایانامه ایشان عبارت است از:  
babakazarnavid@ubonab.ac.ir



محسن عبدالحسین‌زاده دانشآموخته رشته ریاضی کاربردی گرایش پژوهش در عملیات است. او استادیار گروه ریاضی و علوم کامپیوتر دانشگاه بناب است. زمینه‌های پژوهشی وی شامل بهینه‌سازی شبکه، بهینه‌سازی ترکیباتی، الگوریتم‌های ابتكاری و فراابتکاری، تصمیم‌گیری غیرقطعی، هوش مصنوعی و یادگیری ماشین است. هم‌اکنون او در زمینه استفاده از یادگیری ماشین در حوزه مسیریابی، تشخیص بیماری در حوزه پزشکی و الگوریتم‌های ترکیبی کار پژوهشی خود را ادامه می‌دهد.

نشانی رایانامه ایشان عبارت است از:  
mohsen.ab@ubonab.ac.ir