Journal of Health and Biomedical Informatics 2025; 11(4): 306-322
doi: 10.34172/jhbmi.2025.03
Medical Informatics Research Center, Kerman University of Medical Sciences

Original article

Differential Diagnosis of Precancerous and Cancerous Oral Lesions Based on an Integrated Artificial Intelligence Model

Rouhollah Maghsoudi[1]*, Mehdi Tavan[2]

1. Department of Computer Engineering, Nur Branch, Islamic Azad University, Nur, Iran
2. Department of Electrical Engineering, Nur Branch, Islamic Azad University, Nur, Iran

ARTICLE INFO:

Article History:

Received: 25 Nov 2024

Accepted:1 Mar 2025

Published: 18 Mar 2025

**Corresponding Author:*

Rouhollah Maghsoudi

Email:
r.maghsoudy@srbiau.ac.ir

Citation: Maghsoudi R, Tavan M. Differential Diagnosis of Precancerous and Cancerous Oral Lesions Based on an Integrated Artificial Intelligence Model. Journal of Health and Biomedical Informatics 2025; 11(4): 306-22. [In Persian]

Introduction: Early detection of precancerous and cancerous oral lesions is essential for improving treatment outcomes and reducing patient mortality. However, the similarity of these lesions to benign lesions complicates the diagnostic process. Computer-aided diagnostic (CAD) systems can enhance diagnostic accuracy and reduce the time required for diagnosis. This study aimed to develop an integrated model for the diagnosis of oral lesions

Method: In this study, clinical images of patients with leukoplakia, lichen planus, and oral squamous cell carcinoma were collected. After preprocessing the images to improve quality and remove noise, key features were extracted using the SURF algorithm. To reduce data dimensions and select effective features, the K-means clustering algorithm was employed, resulting in a reduction to 30 features. Image classification was performed using five machine learning algorithms: support vector machine (SVM), multilayer neural network (MLP), radial basis function (RBF), decision tree, and Bayesian classifier. The performance of these algorithms was evaluated comparatively.

Results: The results indicated that SVM excelled in detecting oral lesions, achieving an accuracy of 95%. This algorithm demonstrated significant superiority over other methods due to its ability to manage high-dimensional data and its capabilities for both linear and nonlinear separation. While MLP and RBF also provided acceptable results, their accuracy was lower than that of SVM. Employing K-means for dimensionality reduction improved both the speed and accuracy of classification.

Conclusion: This study presents, for the first time, an integrated model for high-accuracy diagnosis of oral lesions using imaging. This approach minimizes misdiagnosis errors and reduces the time and costs associated with diagnosis. The application of artificial intelligence in diagnosing oral lesions can enhance healthcare quality as an auxiliary tool alongside dental professionals. This model holds potential for development in other medical fields and can serve as a reference for future research.

Keywords: Artificial intelligence, Machine learning algorithms, Classification, Feature extraction, Oral lesions.

© 2025 The Author(s); Published by Kerman University of Medical Sciences. This is an open-access article distributed under the terms of the Creative Commons Attribution License (http://creativecommons.org/licenses/by/4.0/), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cite

[Downloaded from jhbmi.ir on 2026-11-25]

[DOI: 10.34172/jhbmi.2025.03]

مجله انفورماتیک سلامت و زیست پزشکی دوره یازدهم، شماره چهارم، سال ۱۴۰۳، ص ۳۲۲-۳۰۶
doi: 10.34172/jhbmi.2025.03
مرکز تحقیقات انفورماتیک پزشکی، دانشگاه علوم پزشکی کرمان

مقاله پژوهشی

تشخیص افتراقی ضایعات پیش سرطانی و سرطانی دهانی مبتنی بر یک مدل یکپارچه هوش مصنوعی

روح اله مقصودی[1*]، مهدی توان[2]

۱. گروه مهندسی کامپیوتر، واحد نور، دانشگاه آزاد اسلامی، نور، ایران

۲. گروه مهندسی برق، واحد نور، دانشگاه آزاد اسلامی، نور، ایران

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۳/۹/۵

پذیرش: ۱۴۰۳/۱۲/۱۱

انتشار برخط: ۱۴۰۳/۱۲/۲۸

نویسنده مسئول:

روح اله مقصودی

ایمیل:

r.maghsoudy@srbiau.ac.ir

ارجاع: مقصودی روح اله، توان مهدی. تشخیص افتراقی ضایعات پیش سرطانی و سرطانی دهانی مبتنی بر یک مدل یکپارچه هوش مصنوعی. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۳؛ ۱۱(۴): ۲۲-۳۰۶.

چکیده

مقدمه: تشخیص به‌موقع ضایعات پیش‌سرطانی و سرطانی دهان نقش اساسی در بهبود نتایج درمانی و کاهش مرگ‌ومیر بیماران دارد. با این حال، شباهت ظاهری این ضایعات با ضایعات خوش‌خیم، فرآیند تشخیص را پیچیده می‌کند. سیستم‌های تشخیصی به کمک کامپیوتر (CAD)، به‌عنوان ابزارهای کمکی، می‌توانند دقت تشخیص را افزایش داده و زمان آن را کاهش دهند. این مطالعه با هدف توسعه یک مدل یکپارچه برای تشخیص ضایعات دهانی انجام شد.

روش: در این مطالعه، تصاویر بالینی از بیماران مبتلا به لوکوپلاکیا، لیکن‌پلان و کارسینوم سلول‌های سنگفرشی دهان جمع‌آوری شد. پس از پیش‌پردازش تصاویر برای بهبود کیفیت و حذف نویز، ویژگی‌های کلیدی با الگوریتم SURF استخراج شدند. برای کاهش ابعاد داده‌ها و انتخاب ویژگی‌های مؤثر، از الگوریتم خوشه‌بندی K-means استفاده شد که تعداد ویژگی‌ها را به ۳۰ ویژگی کاهش داد. طبقه‌بندی تصاویر با استفاده از پنج الگوریتم یادگیری ماشین شامل ماشین بردار پشتیبان (SVM)، شبکه عصبی چندلایه (MLP)، توابع پایه شعاعی (RBF)، درخت تصمیم و دسته‌بندی‌کننده بیزی انجام شد. عملکرد این الگوریتم‌ها به‌صورت مقایسه‌ای ارزیابی شدند.

نتایج: نتایج نشان داد که SVM با دقت ۹۵٪ بهترین عملکرد را در تشخیص ضایعات دهانی دارد. این الگوریتم به دلیل توانایی مدیریت داده‌های با ابعاد بالا و قابلیت تفکیک خطی و غیرخطی، برتری قابل توجهی نسبت به سایر روش‌ها نشان داد. الگوریتم‌های دیگر مانند MLP و RBF نیز نتایج قابل قبولی ارائه کردند، اما دقت آن‌ها کمتر از SVM بود. استفاده از K-means برای کاهش ابعاد ویژگی‌ها، سرعت و دقت طبقه‌بندی را بهبود بخشید.

نتیجه‌گیری: این مطالعه، برای نخستین بار، یک مدل یکپارچه از عکس‌برداری تا تشخیص ضایعات دهانی با دقت بالا ارائه کرد. این رویکرد خطاهای تشخیصی اشتباه را کاهش داده و زمان و هزینه‌های مرتبط با تشخیص را کاهش می‌دهد. استفاده از هوش مصنوعی در تشخیص ضایعات دهانی می‌تواند به عنوان یک ابزار کمکی در کنار متخصصان دندانپزشکی، کیفیت مراقبت‌های بهداشتی را بهبود بخشد. این مدل پتانسیل توسعه در سایر زمینه‌های پزشکی را دارد و می‌تواند به عنوان مرجعی برای تحقیقات آینده مورد استفاده قرار گیرد.

کلمات کلیدی: هوش مصنوعی، الگوریتم‌های یادگیری ماشین، دسته بندی، استخراج ویژگی، ضایعات دهانی

[Downloaded from jhbmi.ir on 2026-11-25]

[DOI: 10.34172/jhbmi.2025.03]

مقدمه

در عصر اطلاعات، هوش مصنوعی و سیستم‌های هوشمند به عنوان ابزارهایی قدرتمند در تشخیص و درمان بیماری‌ها مورد استفاده قرار می‌گیرند. از جمله حوزه‌هایی که به کمک این فناوری‌ها نیاز دارد، تشخیص ضایعات پیش‌سرطانی و سرطانی دهان است. این ضایعات به دلیل تنوع بالینی و شباهت ظاهری، چالش‌برانگیز هستند و تشخیص دقیق آن‌ها می‌تواند نقش حیاتی در بهبود نتایج درمانی داشته باشد [۱].

امروزه هوش مصنوعی (Artificial Intelligence) در تمام حوزه‌های علوم، به‌ویژه در سلامت، ورود پیدا کرده و مزایای زیادی دارد. این فناوری خسته نمی‌شود، از انجام کارهای تکراری خسته نمی‌شود و تصمیمات دقیق‌تری می‌گیرد. دلیل این دقت بالا، دسترسی به منابع اطلاعاتی متعدد، تحلیل سریع داده‌ها و عدم تحت تأثیر قرار گرفتن از عواطف است که باعث می‌شود در کوتاه‌ترین زمان، بهترین تصمیمات را بگیرد و خطاهای انسانی را کاهش دهد [۲]. پردازش کامپیوتری و هوش مصنوعی به توسعه سیستم‌های پشتیبان تصمیم‌گیری در حوزه پزشکی کمک کرده‌اند. این سیستم‌ها از نظر پزشکان، می‌توانند باعث کاهش واکنش‌های آلرژیک شدید، تداخل دارویی، و دسترسی سریع به سوابق بیمار شوند. همچنین، ثبت دستورات به‌صورت کامپیوتری، دسترسی به اطلاعات به‌روز و کاهش عوارض اعمال پزشکی از دیگر مزایای این سیستم‌ها است [۳]. در شاخه‌های مختلف علوم پزشکی ابزارهای هوشمند وارد شده و در زمینه‌های تشخیصی کمک قابل توجهی به متخصصان مربوطه نموده‌اند، که از آن جمله می‌توان به تشخیص به موقع سرطان سینه، نارسایی‌های قلبی، بیماری‌های پوستی، نارسای‌های کبدی، سرطان سلول‌های سنگفرشی، ملانوما و ... اشاره کرد [۵، ۴]. پیشرفت علم و ارتباطات بین‌رشته‌ای، به‌ویژه در حوزه‌های پزشکی و مهندسی، باعث شده است که روش‌های نوینی مانند هوش مصنوعی و محاسبات نرم برای شناسایی سریع‌تر و دقیق‌تر بیماری‌ها مورد استفاده قرار گیرند. این روش‌ها که ریشه در علوم کامپیوتر دارند، امروزه در حوزه‌هایی مانند علوم پزشکی و زیستی نیز کاربرد گسترده‌ای پیدا کرده‌اند. در سال‌های اخیر، انفورماتیک پزشکی و بیوانفورماتیک با استفاده از تکنیک‌های محاسباتی برای تحلیل داده‌های پزشکی و بیولوژیکی، رشد قابل توجهی داشته‌اند که به بهبود تشخیص و درمان بیماری‌ها کمک کرده است [۶]. سیستم‌های هوشمند با مزایایی مانند پردازش سریع و دقیق اطلاعات، توانایی انجام پرسش‌های هدفمند، در نظر گرفتن جزئیات و دستیابی سریع به پاسخ، نقش مهمی در پزشکی ایفا می‌کنند. با این حال، در حوزه دندانپزشکی، مطالعات کمتری انجام شده است. ضایعات شایع دهان مانند لیکن‌پلان، لوکوپلاکیا و کارسینوم سلول‌های سنگفرشی نیاز به تشخیص دقیق و به‌موقع دارند تا از پیشرفت بیماری و کاهش شانس بقاء جلوگیری شود. متأسفانه، بسیاری از بیماران در مراحل پیشرفته به پزشک مراجعه می‌کنند که این موضوع به دشواری تشخیص زودهنگام مرتبط است. هوش مصنوعی می‌تواند به عنوان یک ابزار کمکی، در تشخیص دقیق‌تر و سریع‌تر این بیماری‌ها مؤثر باشد [۷]. از سوی دیگر، تشخیص صحیح ضایعات نیز دارای اهمیت بسیاری بوده، هر گونه نارسایی در آن می‌تواند آسیب‌های جبران ناپذیری را به دنبال داشته باشد. تشخیص صحیح موجب می‌شود که از درمان‌های نامناسب و غیرضروری اجتناب شود. درمان نامناسب یک ضایعه علاوه بر تحمیل هزینه‌های سنگین به بیمار، در برخی موارد باعث پیشرفت بیماری اولیه و آسیب به اندام‌های دیگر می‌گردد.

عوامل گوناگونی وجود دارند که می‌توانند در کار تشخیص ضایعات اختلال و نارسایی ایجاد کنند. یکی از عوامل، تعدد بیماری‌هایی است که دارای ضایعاتی در حفره دهان می‌باشند و دندانپزشک هر چند ممکن است از این بیماری‌ها آگاهی کافی داشته باشد؛ اما تعدد بیماری‌ها موجب می‌شود که او به هنگام مواجه شدن با یک ضایعه خاص برخی از این بیماری‌ها را به خاطر خطای انسانی نادیده بگیرد. علاوه بر این، اطلاعات دندانپزشکی روز به روز در حال گسترش و توسعه هستند و دندانپزشکی که از اطلاعات جدید و بروز آگاهی کافی نداشته باشد در تشخیص ضایعات دچار مشکل می‌شود. از طرف دیگر، کار مداوم دندانپزشکی در طول روز ذهن دندانپزشک را که باید حجم وسیعی از اطلاعات را پردازش و در هر لحظه تصمیمی قاطع اتخاذ نماید، خسته و فرسوده می‌سازد. عامل دیگری که کار تشخیص ضایعات را مشکل می‌کند، تشابه نمای بالینی ضایعات گوناگون به یکدیگر است. از آنجا که تشخیص به موقع و صحیح ضایعات که خود طرح درمان خاصی را برمی‌گزینند، می‌تواند جلوی بسیاری از مشکلات و گسترش بیماری را بگیرد و با توجه به مشکلات عنوان شده در تشخیص ضایعات، استفاده از یک سیستم پشتیبان تصمیم‌گیری با توانایی پردازش حجم وسیعی از اطلاعات و تصمیم‌گیری‌های منطقی با سرعت بسیار بالا لازم و ضروری می‌باشد [۸]. با این حال اگر روش‌های پشتیبان تصمیمی در کنار موارد ذکر شده قرار بگیرند، مسلماً

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

مجله انفورماتیک سلامت و زیست پزشکی دوره یازدهم، شماره چهارم، سال ۱۴۰۳، ص ۳۲۲-۳۰۶
doi: 10.34172/jhbmi.2025.03
مرکز تحقیقات انفورماتیک پزشکی، دانشگاه علوم پزشکی کرمان

می‌توانند تشخیص افتراقی با صحت و دقت بهتر از بیماری ارائه کنند. در کنار همه موارد ذکر شده یک سیستم هوشمند پشتیبان تصمیم در بستر ساختار پزشکی از راه دور(تله مدیسین) بسیار می‌تواند به کاهش زمان تشخیص بیماری و در ادامه کاهش هزینه‌های پزشکی برای بیمار مؤثر باشد [۹]. تقریباً در سال ۳۷۷ هزار نفر در جهان با سرطان دهان تشخیص داده می‌شوند که نزدیک به ۸۰٪ آن کارسینوم سلول‌های سنگفرشی دهان می‌باشد که در آستر مخاط روی می‌دهد. علیرغم پیشرفت‌هایی که در رادیوتراپی، کموتراپی و توسعه تکنیک‌های جراحی روی داده است، OSCC(Oral Squamous Cell Carcinoma) هنوز یکی از دلایل بالای مرگ و میر در جهان است و امید به زندگی برای ۵ سال کمتر از ۵۰٪ است. OLP (Oral Lichen Plan) و OLK (Oral Leukoplakia) دو نوع از بیماری‌های پیش سرطانی رایج هستند که در نهایت می‌توانند به OSCC تبدیل شوند. OLP یک بیماری پوستی مخاطی مزمن است که سازمان بهداشت جهانی آن را به عنوان یک وضعیت بالقوه پیش سرطانی، که نشان دهنده یک حالت کلی مرتبط با یک خطر افزایش یافته سرطان است، معرفی می‌کند. OLK بیشترین ضایعه پیش سرطانی تکرار شونده دهانی است و به طور متغیری در ارتباط با تغییرات بدخیمی می‌باشد[۱۰].

مطالعاتی در زمینه تشخیص بیماری‌های دهان و سایر بیماری‌ها در دندانپزشکی و پزشکی با بهره‌گیری از تکنیک‌های پردازش تصویر و الگوریتم‌های دسته‌بندی و پیش‌بینی صورت گرفته است، ولی تا به امروز الگوریتم‌های یادگیری ماشین کمی برای این منظور توسعه داده شده است. مطالعات قبلی نشان داده‌اند که سیستم‌های هوشمند می‌توانند در تشخیص بیماری‌های مختلف پزشکی مؤثر باشند. به عنوان مثال، Keser و همکاران یک الگوریتم یادگیری عمیق برای طبقه‌بندی ضایعات لیکن پلان دهان ارائه کردند که دقت مناسبی در تشخیص داشت [۱۱]. همچنین Achararit و همکاران مطالعه‌ای برای تشخیص لیکن پلان دهانی مبتنی بر هوش مصنوعی با استفاده از شبکه‌های عصبی کانولوشنال عمیق انجام دادند. در این مطالعه، یک مجموعه داده جدید شامل ۶۹۰ عکس بالینی OLP و ۴۸۰ عکس غیر OLP برای آموزش و توسعه مدل‌های یادگیری ماشین ایجاد شد که برای تشخیص ضایعات OLP و غیر OLP با استفاده از عکس‌های بالینی استفاده شد. این تحقیق نشان می‌دهد که مدل‌های CNN می‌توانند به دقت ۸۲ تا ۸۸ درصد در یک مجموعه داده بسیار کوچک دست یابند [۱۲]. Adeoye و همکاران یک مدل یادگیری ماشین برای پیش‌بینی خطر سرطان دهان در بیماران مبتلا به لکوپلاکی و موکوزیت لیکنوئید دهان ارائه کردند. این اختلالات، که جزء ضایعات پیش‌سرطانی دهان هستند، ممکن است به سرطان تبدیل شوند، اما تمام بیماران این ریسک را ندارند. محققان اطلاعات ۱,۱۸۷ بیمار از سه مؤسسه بهداشتی در هنگ کنگ، نیوکاسل انگلستان و لاگوس نیجریه را تحلیل کردند. نتایج نشان داد که دو مدل ریسک بهینه توسعه‌داده‌شده، به ترتیب با دقت‌های ۹۷ و ۹۴ درصد، قادر به پیش‌بینی تحول بدخیم در این بیماران هستند. این مدل‌ها می‌توانند به برنامه‌ریزی درمانی فردی و تعیین رژیم‌های پیگیری بهینه کمک کنند [۱۳]. Xu و همکاران یک رویکرد خودکار برای پیش‌بینی پاسخ به درمان سرکوب‌کننده ایمنی در بیماری لیکن پلان دهان (OLP) توسعه دادند. این بیماری التهابی مزمن است که مدیریت آن عمدتاً بر کنترل التهاب با استفاده از داروهای سرکوب‌کننده سیستم ایمنی متمرکز است. پاسخ به این نوع درمان متفاوت است، بنابراین پیش‌بینی دقیق پاسخ درمانی اهمیت زیادی دارد. در این مطالعه، از ۲۰۸ تصویر پاتولوژیک OLP استفاده شد و ۳۸ ویژگی استخراج شد که ۶ ویژگی به‌طور قابل توجهی بر پاسخ به درمان تأثیر داشتند. با استفاده از رگرسیون لجستیک، مدل پیش‌بینی توسعه داده شد که دقت ۹۰ درصد و سطح زیر منحنی AUROC برابر با ۰/۹۴۷ داشت. این مطالعه نشان داد که می‌توان ویژگی‌های بیولوژیکی مرتبط با پاسخ درمانی را به‌صورت خودکار از تصاویر پاتولوژیک بدون نیاز به حاشیه‌نویسی استخراج کرد [۱۴]. Idrees و همکاران یک الگوریتم یادگیری ماشین برای شناسایی دقیق لیکن پلان دهانی (OLP) ارائه کردند. این الگوریتم با استفاده از تصاویر میکروسکوپی دیجیتالی، سلول‌های التهابی استرومایی، شامل سلول‌های تک‌هسته‌ای و گرانولوسیت‌ها، را شناسایی و کمی‌سازی کرد. نتایج نشان داد که تعداد سلول‌های التهابی در OLP به‌طور معناداری بیشتر از ضایعات مشابه دیگر است. روش پیشنهادی با دقت بالایی (مساحت زیر منحنی ۰/۹۸۲ و ۰/۹۸۸) توانست OLP را تشخیص دهد و شناسایی نقطه برش بر اساس سلول‌های تک‌هسته‌ای حساسیت ۱۰۰٪ و دقت ۹۴/۶۲٪ را نشان داد [۱۵]. Alhazmi و همکاران یک مدل شبکه عصبی مصنوعی برای پیش‌بینی خطر ابتلاء به سرطان دهان توسعه دادند. این مدل با استفاده از ۲۹ متغیر مرتبط با عوامل خطر، وضعیت پزشکی و ویژگی‌های کلینیکی-پاتولوژیک بیماران، طراحی شد. مجموعه داده شامل ۷۳ بیمار بود که به صورت تصادفی به دو گروه آموزشی (۵۴ نفر) و آزمایشی (۱۹ نفر) تقسیم شدند. از مجموع بیماران، ۲۲ مورد (۳۰/۱۳٪) خوش‌خیم و ۵۱ مورد (۶۹/۸۶٪) بدخیم تشخیص داده شدند. تجزیه و تحلیل نتایج نشان داد

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

که دقت مدل در پیش‌بینی سرطان دهان ۷۸/۹۵٪ بود [۱۶]. فصیحی و همکاران یک روش سه‌مرحله‌ای شامل پیش‌پردازش (حذف نویز و ارتقاء کیفیت)، دسته‌بندی تصاویر (تشخیص ملانوم و غیرملانوم)، و استخراج ویژگی‌ها (با تبدیل موجک) برای تشخیص ملانوم ارائه کردند. صحت این روش حدود ۹۰٪ بود. در مطالعات مشابه، صحت تشخیص بین ۹۲-۶۰٪ ، موارد مثبت کاذب ۷/۲-۴/۲٪ و منفی کاذب ۵/۹-۴/۳٪ گزارش شده است [۱۷].

مقصودی و همکاران یک سیستم هوشمند تشخیصی ضایعات سرطانی و پیش‌سرطانی دهانی شامل لیکن پلان، لوکوپلاکیا و کارسینوم سلول‌های سنگفرشی دهان را مبتنی بر شبکه عصبی مصنوعی پیشنهاد کردند. در این مطالعه یک مجموعه داده‌ای از ۱۵۰ بیمار شامل ویژگی‌های مشترک سه بیماری نظیر نوع ضایعه، محل ضایعه، سن بیمار و جنسیت بیمار تهیه شد. این منبع داده‌ای برای آموزش یک شبکه عصبی چندلایه(Multi-layer perceptron) و در نهایت استفاده از این شبکه برای تشخیص و پیش‌بینی بیماری‌ها به کار گرفته شد. درصد خطای آزمون ۰/۱۹۶ حکایت از مناسب بودن این مدل تشخیصی دارد [۱۸]. Rosado و همکاران یک مدل مؤثر و هوشمند مبتنی بر ماشین‌های بردار پشتیبان را جهت پیش‌بینی میزان پیش آگهی در بیماران مبتلا به کارسینوم سلول‌های سنگفرشی دهان معرفی کردند. ۳۴ تفاوت بالینی و مولکولی در ۶۹ بیمار مبتلا به OSCC مورد مطالعه قرار گرفت. اجرای مدل پیش‌بینی کننده با استفاده از ماشین‌های بردار پشتیبان به عنوان یک الگوریتم دسته‌بندی انجام شد. میزان درصد کلی صحت دسته‌بندی ۹۸/۵۵٪ به دست آمد. تکنیک‌های بردار پشتیبان ابزارهایی را ایجاد می‌کنند که می‌توانند بقاء بیماران مبتلا به OSCC را با صحت بالا پیش‌بینی کنند [۱۹].

هدف اصلی این تحقیق، طراحی و ارائه یک مدل یکپارچه تشخیصی مبتنی بر هوش مصنوعی است که بتواند به عنوان یک ابزار کمکی در کنار متخصصان، دقت و سرعت تشخیص ضایعات دهان را افزایش دهد. این مدل با بهره‌گیری از تکنیک‌های پیشرفته پردازش تصویر و الگوریتم‌های یادگیری ماشین، قصد دارد ضمن کاهش خطاهای انسانی، زمان تشخیص را کوتاه‌تر کرده و هزینه‌های درمانی را نیز کاهش دهد.

بیماری‌های دهان

لیکن پلان

واکنش‌های لیکنوئید بیانگر گروهی از ضایعات با اتیولوژی مختلف هستند که دارای نمای بالینی و بافت‌شناسی مشترک می‌باشند. واکنش‌های لیکنوئید دهانی شامل اختلالات زیر می‌باشند: لیکن‌پلان، واکنش‌های تماسی لیکنوئید، بثورات دارویی لیکنوئید و واکنش‌های لیکنوئیدی بیماری پیوند علیه میزبان (Graft-versus-host disease) لیکن پلان یک نوع خود ایمنی التهابی از بیماری پوستی-مخاطی است، که می‌تواند اپی‌تلیوم سنگفرشی، پوست، مخاط دهان و ناحیه تناسلی را درگیر کند. در مطالعات میزان شیوع مختلفی برای OLP گزارش شده است و از ۲/۲-۰/۵٪ متغیر است. نسبت زنان بیشتر از مردان است، اما این مورد در جمعیت عمومی نیست. میانگین سنی در زمان تشخیص تقریباً ۵۵ سال می‌باشد. زنان به نسبت ۳ به ۲، بیشتر از مردان گرفتار می شوند. به طور معمول ضایعات لیکن‌پلان به صورت دو طرفه مخاط باکال را درگیر می‌کنند. لیکن پلان دارای شش نمای بالینی می‌باشد که عبارت‌اند از: رتیکولر، پاپولر، پلاک مانند، آتروفیک، اروزیو/ اولسراتیو و بولوز [۱۹،۲۰].

لکوپلاکیا

لکوپلاکیای دهانی به عنوان یک ضایعه سفید مخاط دهان شناخته می‌شود که نمی‌تواند به عنوان هیچ ضایعه تعریف‌پذیر دیگری مشخص گردد. بروز لکوپلاکیا به عنوان ضایعه پیش بدخیمی، تغییرات ژنتیکی مختلفی را شامل می‌شود. یک بازنگری جامع در کل جهان نشان‌دهنده شیوع ۲/۶٪ می‌باشد. اکثر لکوپلاکیاهای دهانی در بیماران(مردان) بالای ۵۰ سال دیده می‌شود و در افراد زیر ۳۰ سال غیر شایع است. عوامل اتیولوژیک ابتلاء به لکوپلاکیا: مصرف تنباکو، الکل و ویروس پاپیلومای انسانی (Human Papilloma virus) می‌باشند. مصرف تنباکو، الکل، مصرف Betel(برگ تنبول)، مصرف سانگواینارین به عنوان فاکتورهای خطر ابتلاء به لکوپلاکیا در نظر گرفته می‌شوند. این اختلال می‌تواند به نوع هموژن و غیر هموژن تقسیم شود. تشخیص قطعی لکوپلاکیا و پروگنوز بیماری به وسیله بیوپسی قابل پیش‌بینی است[۱۹،۲۰].

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

مجله انفورماتیک سلامت و زیست پزشکی دوره یازدهم، شماره چهارم، سال ۱۴۰۳، ص ۳۲۲-۳۰۶
doi: 10.34172/jhbmi.2025.03
مرکز تحقیقات انفورماتیک پزشکی، دانشگاه علوم پزشکی کرمان

کارسینوم سلول‌های سنگفرشی دهان

کارسینوم سلول‌های سنگفرشی دهان (**O**ral **S**quamous **C**ell **C**arcinoma)، بیشترین موارد مربوط به سرطان دهان را به خود اختصاص داده است. اتیولوژی OSCC مربوط به وضعیت‌ها و حالات بالقوه سرطانی(پیش سرطانی) می‌شود که اگر این وضعیت‌ها و حالات پیش سرطانی پیشرفت کنند، می‌توانند تبدیل به OSCC شوند. بیماری‌ها و ضایعات مختلفی وجود دارند که می‌توانند بالقوه سرطانی باشند. این ضایعات عبارت‌اند از: لکوپلاکیا، لکوپلاکیای زیر زبانی، کاندیدا لکوپلاکیا، فیبروز تحت مخاطی، ضایعات لیکنوئید، سابقه بدخیمی قبلی در دهان، لوپوس اریتماتوز و ... فاکتورهای خطر ابتلاء به OSCC، مصرف تنباکو، الکل و مصرف Betel، فاکتورهای تغذیه‌ای(کمبود ویتامین A و کاروتنوئید) و سایر فاکتورها(استفاده از دنچر، دندان‌ها یا ترمیم‌های نامنظم و عادت مزمن جویدن گونه) می‌باشد[۱۹،۲۰].

کارسینوم سلول سنگفرشی دهان تظاهرات بالینی مختلفی دارد که عبارت اند از:

اگزوفیتیک (توده‌ای؛ قارچی شکل، پاپیلری، وروسی فرم (گل کلمی))، اندوفیتیک (مهاجم، فرورفته، زخمی)، لکوپلاکیایی (پلاک سفید) اریتروپلاکیایی (پلاک قرمز)، اریترولکوپلاکیایی (پلاک ترکیبی از قرمز و سفید) [۲۱].

این بیماری بیشتر به صورت یک ضایعه مخاطی مزمن تظاهر پیدا می‌کند. تشخیص قطعی OSCC با برداشت بیوپسی از بیمار مشخص می‌شود.

روش کار

مجموعه داده‌ای

برای تهیه مجموعه داده‌ای از ۲۱۰ تصویر استفاده شد. تصاویر از اطلس‌های معتبر دندانپزشکی و بیماران درمانگاه‌های دندانپزشکی دانشگاه علوم پزشکی گیلان با اخذ رضایت‌نامه از بیماران تهیه شده‌اند. به بیان دیگر منبع داده شامل ۲۱۰ نمونه، دو کلاس و ۳۰ ویژگی می‌باشد. کار کلاس بندی و ارزیابی نتایج با دو منبع داده‌ای به ترتیب با ۱۵ و ۳۰ ویژگی انجام شد. جزئیات داده‌ها عبارت‌اند از:

دسته اول: نرمال (۵۶)

دسته اول: بیمار (۱۵۴)

اطلاعات آماری ۳۰ ویژگی در جدول ۱ آمده است.

جدول ۱: اطلاعات آماری هر یک از ویژگی‌های منبع داده‌ای

شماره ویژگی	میانگین	انحراف معیار	مینیمم	ماکزیمم
۱	۶/۰۲۴	۱۱/۹۸۶	۰	۱۲۴
۲	۱۰/۴۴۸	۲۴/۶۲۲	۰	۱۶۲
۳	۵/۵۳۸	۱۵/۲۹۸	۰	۱۳۶
۴	۳/۵۱	۵/۷۳۱	۰	۳۶
۵	۸/۱۸۱	۱۵/۵۶	۰	۱۲۲
۶	۷/۱۸۶	۱۶/۳۶۶	۰	۱۳۴
۷	۶/۳۲۴	۱۰/۰۹۱	۰	۷۱
۸	۸/۳۸۶	۱۸/۴۴۷	۰	۱۴۶
۹	۴/۶۷۱	۶/۹۳۳	۰	۴۳
۱۰	۶/۴۷۶	۱۱/۹۵۲	۰	۱۱۸
۱۱	۵/۷۵۲	۱۷/۸۳۲	۰	۲۰۶
۱۲	۵/۳۳۸	۹/۱۰۶	۰	۵۷
۱۳	۴/۷۳۸	۵/۷۱۳	۰	۳۷
۱۴	۴/۶۹	۶.۵۱۱	۰	۳۹
۱۵	۶/۰۰۵	۹/۰۱۷	۰	۷۱
۱۶	۸/۶۲۹	۲۰/۹۴	۰	۱۳۰
۱۷	۹/۵۷۶	۲۱/۹۷۸	۰	۱۶۵
۱۸	۵/۷۹	۱۴/۲۰۱	۰	۱۲۶
۱۹	۴/۴۴۸	۶/۵۶۷	۰	۴۳

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

جدول ۱: اطلاعات آماری هر یک از ویژگی های منبع داده‌ای(ادامه)

۴۱	۰	۶/۶۷۶	۴/۰۱	۲۰
۵۹	۰	۷/۶۵۶	۶/۸۲۴	۲۱
۵۰	۰	۶/۶۰۱	۳/۸۱۴	۲۲
۱۲۰	۰	۱۶/۵۷۸	۸/۲۴۸	۲۳
۸۵	۰	۱۰/۰۶۹	۶/۳۹۵	۲۴
۲۸۲	۰	۲۳/۴۶۸	۹/۲۱	۲۵
۹۶	۰	۹/۷۷۲	۵/۵۷۶	۲۶
۹۲	۰	۱۰/۴۶۵	۵/۹۶۷	۲۷
۶۵	۰	۸/۸۷۱	۵/۴۸۱	۲۸
۳۳	۰	۵/۱۸۷	۳/۹۱۴	۲۹
۴۶	۰	۶/۶	۳/۷۲۹	۳۰

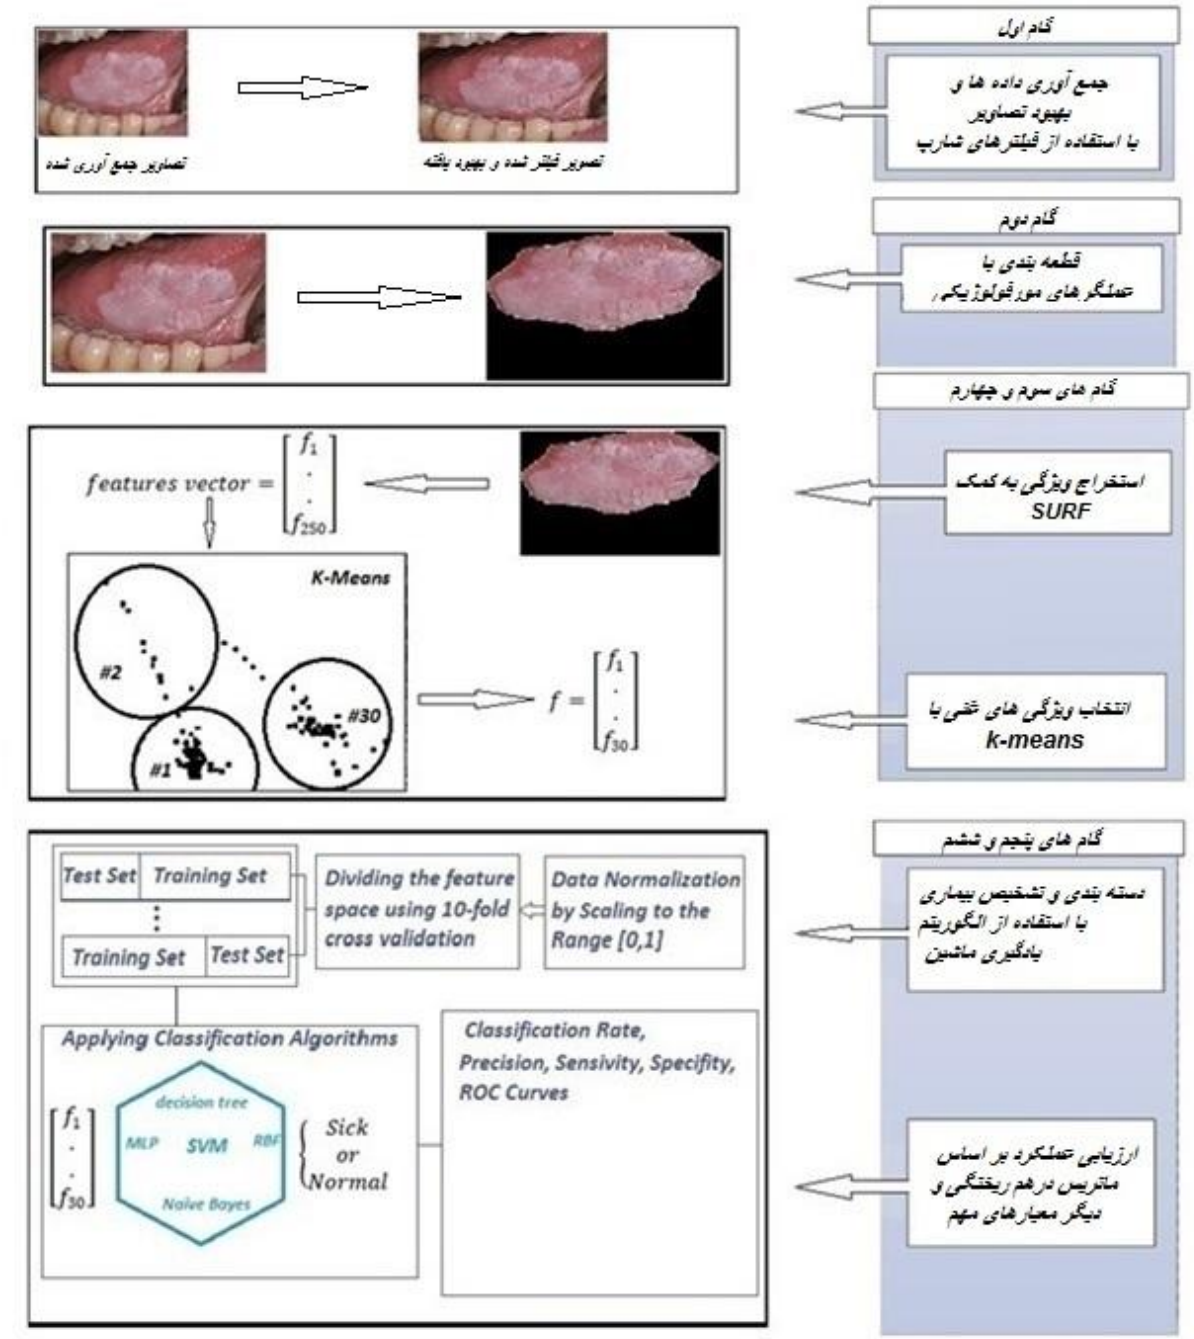
اگر به جدول فوق توجه شود، ویژگی‌ها دارای بازه‌های متفاوتی هستند. همین مسئله تأثیر هر ویژگی در خروجی دسته‌بندی کننده را با توجه به در نظر گرفتن پارامترهای وزن یکسان به خوبی بر نخواهد تافت. برای اعمال تأثیر یکسان، داده‌ها به بازه $[0,1]$ نرمال شدند.

استراتژی پیشنهادی

این مطالعه یک مدل یکپارچه و دقیق برای تشخیص بیماری‌های دهان ارائه می‌دهد. رویکرد پیشنهادی این مطالعه از شش مرحله اساسی مشتمل بر گام‌های یک و دو برای پیش‌پردازش(شامل بهبود کیفیت و سپس قطعه بندی تصاویر)، گام‌های سه و چهار برای استخراج ویژگی‌های مناسب و در نهایت گام‌های پنج و شش جهت انتخاب مدل دسته‌بندی مناسب و در نهایت ارزیابی مدل ساخته شده است. گام‌های الگوریتم پیشنهادی با جزئیات بیشتر از دیاگرام بلوکی شکل ۱ تبعیت می‌کند. در این مدل پیشنهادی، کیفیت تصاویر بر اساس فیلتر شارپ افزایش داده شد. پس از این مرحله تقسیم بندی برای جداسازی بخش ملانوما از هر تصویر انجام شد. روش تقسیم بندی مورد استفاده در این مطالعه بر اساس عملگرهای مورفولوژیکی است که Fassihi و همکاران [۱۷] از آن استفاده کردند. برای استخراج ویژگی، از الگوریتم Surf(Speed Up Robust Feature) [۲۰] و سپس ویژگی‌های غنی که توسط الگوریتم خوشه‌بندی k-means انتخاب شده‌اند، استفاده شد. در ادامه برخی از الگوریتم‌های یادگیری ماشین برای طبقه‌بندی بیماری‌های دهان اعمال خواهد شد. در نهایت از بین این الگوریتم‌ها بهترین مدل طبقه بندی کننده استخراج شد. شکل ۱ نمودار سلسله مراتبی روش پیشنهادی را نشان می‌دهد.

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

مجله انفورماتیک سلامت و زیست پزشکی دوره یازدهم، شماره چهارم، سال ۱۴۰۳، ص ۳۲۲-۳۰۶
doi: 10.34172/jhbmi.2025.03
مرکز تحقیقات انفورماتیک پزشکی، دانشگاه علوم پزشکی کرمان



شکل ۱: روش سلسله مراتبی پیشنهادی

پیش پردازش تصاویر

در ابتدا کیفیت تصاویر با استفاده از فیلترهای حوزه فضایی برای استخراج ویژگی‌های تصویر بهبود یافت. پیکسل‌های فرکانس پایین آن‌هایی هستند که در مقایسه با پیکسل‌های همسایه خود تفاوت شدیدی در روشنایی ندارند (نقاط با تغییر کند در یک تصویر). از سوی دیگر، پیکسل‌های فرکانس بالا، پیکسل‌هایی هستند که در مقایسه با پیکسل‌های همسایه‌شان، تفاوت شدید روشنایی (لبه‌ها و نویز) دارند. به دلیل داشتن فیلترهای پایین گذر، تصویر صاف خواهد بود، لبه‌ها و نویز را می‌توان تا حدودی کاهش داد و با اعمال فیلتر بالاگذر، تصویر

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

دقیق‌تری به دست می‌آید. فیلتر تیزکننده لاپلاسین به عنوان یک فیلتر بالاگذر برای نشان دادن جزئیات بیشتر تصویر استفاده می‌شود. شکل ۲–ب نتیجه اجرای فیلتر تیزکننده لاپلاسین بر روی شکل ۲–الف را نشان می‌دهد.



شکل ۲: ب– نمونه تصویر پس از اعمال فیلتر تیزکننده



شکل ۲: الف– یک تصویر نمونه

قطعه‌بندی تصاویر

قطعه‌بندی تصویر مرحله دوم تحلیل می‌باشد که به قسمت‌های اصلی قطعه‌بندی تصویر تقسیم شد. این به این معنی است که بخش‌های مختلف تصویر، بسته به کاربرد مورد نظر، از هم جدا می‌شوند تا تجزیه و تحلیل تصویر آسان‌تر شود [۹]. به طور دقیق‌تر، با استفاده از روش قطعه‌بندی، آناتومی دهان بیمار از تصویر خارج می‌شود و بدون توجه به سایر اطلاعات ضروری برای کاربردهای بعدی پردازش می‌شود. شکل ۳– ب نتایج قطعه‌بندی را روی یک تصویر نمونه (شکل ۳–الف) نشان می‌دهد.



شکل ۳: ب– نمونه تصویر پس از قطعه بندی



شکل ۳: الف– نمونه تصویر شارپ شده

برای قطعه‌بندی تصویر، عملگرهای مورفولوژیکی مورد استفاده در [۱۷] به کار گرفته می شود.

انتخاب ویژگی

در این مطالعه الگوریتم SURF برای استخراج ویژگی استفاده شد. چندین نقطه کلیدی از هر تصویر شناسایی و هر توصیفگر استخراج گردید. سپس، تمام توصیفگرهای همه تصاویر با استفاده از الگوریتم خوشه‌بندی k-means به ۳۰ کلاس تقسیم شدند. برای هر تصویر، فرکانس توصیفگرهای مرتبط با هر خوشه در یک هیستوگرام با ۳۰ دسته به دست می‌آید و از این هیستوگرام برای توصیف هر تصویر استفاده شد.

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

مجله انفورماتیک سلامت و زیست پزشکی دوره یازدهم، شماره چهارم، سال ۱۴۰۳، ص ۳۲۲-۳۰۶
doi: 10.34172/jhbmi.2025.03
مرکز تحقیقات انفورماتیک پزشکی، دانشگاه علوم پزشکی کرمان

دسته‌بندی با استفاده از الگوریتم‌های یادگیری ماشین

در نهایت، از الگوریتم‌های مختلف یادگیری ماشین از جمله MLP، طبقه‌بندی‌کننده RBF (Radial Basis Function)، Naïve Bayes، درخت تصمیم و SVM(Support Vector Machine) برای دسته‌بندی ویژگی‌های به‌دست‌آمده از تصاویر و تشخیص وضعیت‌های خروجی استفاده گردید. چندین مقداردهی اولیه برای تنظیم پارامترهای مهم و مؤثر الگوریتم‌های مذکور در فرآیند ساخت مدل تخمینی انجام شد. این مقادیر بر اساس تلاش و آزمایش یا آخرین و بهترین تجربه از تحقیقات مشابه در این زمینه تنظیم شده است.

نتایج

برای ارزیابی عملکرد از اعتبارسنجی متقابل با 10-fold برای ماشین بردار پشتیبان، شبکه عصبی تابع پایه شعاعی، درخت تصمیم، دسته‌بندی کننده بیز و شبکه عصبی چندلایه پرسپترون بهره برده شد. ماتریس‌های درهم ریختگی برای هر یک از دسته‌بندی کننده‌ها در حالتی با ۳۰ ویژگی در ادامه مشاهده شد.

جدول ۲: ماتریس‌های درهم ریختگی برای ماشین بردار پشتیبان، درخت تصمیم، بیز، MLP و RBF

واقعی	دسته بندی شده	MLP	RBF	بیز	درخت تصمیم(C4.5)	SVM
بیمار	نرمال	۱۱	۵	۳	۱۷	۴
	بیمار	۱۴۳	۱۴۹	۱۵۱	۱۳۷	۱۵۰
نرمال	نرمال	۹	۲۰	۲۸	۳۴	۵۰
	بیمار	۴۷	۳۶	۲۸	۲۲	۶

برای ارزیابی مدل پیشنهادی چند معیار شناخته شده و مهم شامل نرخ دسته‌بندی، Precision، Recall، Sensitivity، F-score و Specificity را که غالباً در کارهای دسته‌بندی مورد کاربرد هستند، استفاده شد. جهت فهم و تفسیر بهتر نتایج لازم است توضیح مختصری در خصوص ماهیت معیارهای مذکور داده شود. **Recall**، نسبتی از سیگنال‌های درست پیش‌بینی شده میان همه سیگنال‌های صحیح ممکن است و می‌تواند به عنوان توانایی انجام پیش‌بینی صحیح در نظر گرفته شود. نرخ نمونه‌های درست کلاس‌بندی شده‌ای که واقعاً نمونه‌های پیش‌سرطانی هستند را نشان می‌دهد. به عنوان مثال اگر بگوییم کلاسیفایری ۱۰۰٪ ، **sensitive** است یعنی اینکه همه افراد از کلاس بیمار را بیمار پیش‌بینی کند. **Precision** و **Recall** در جهت عکس هم عمل می‌کنند. وقتی **Precision** افزایش می‌یابد، **recall** معمولاً کاهش می‌یابد و بالعکس. **F – Score**، یک مسامحه‌ای بین **Precision** و **Recall** است. **Specificity**، نسبتی از سیگنال‌های درست میان همه سیگنال‌های پیش‌بینی شده است. اختصاصی بودن، بیانگر توانایی حذف پیش‌بینی‌های نادرست است. اگر بگوییم کلاسیفایری ۱۰۰٪ ، **specific** است یعنی این که هیچ کس از کلاس سالم به عنوان بیمار کلاس‌بندی نشود. زمانی یک استراتژی دقیق محسوب می‌شود که حساسیت و اختصاصی بودن آن به طور همزمان بالا و نزدیک مقدار یک، باشند. در مواردی که حساسیت بالا است، ولی اختصاصی بودن کم است در اصطلاح می‌گویند استراتژی تمایل دارد بیش از حد پیش‌بینی (Overpredicted) کند. از طرفی دیگر، اگر حساسیت پایین باشد، ولی اختصاصی بودن بالا باشد، استراتژی بسیار محافظه‌کار است و قدرت پیش‌بینی کافی را ندارد. به دلیل آن که هیچ کدام از دو پارامتر حساسیت و اختصاصی بودن به تنهایی و به طور کامل نمی‌تواند میزان صحت را بیان کند، بنابراین بهتر است این دو فاکتور در یک مقدار خلاصه شود.

این معیارها برای دو حالت دسته‌بندی به ترتیب با ۱۵ و ۳۰ ویژگی به دست آورده شد (جداول ۳، ۴، ۵ و ۶). ارزیابی عملکرد حاکی از خروجی مناسب‌تر طبقه‌بندی کننده‌ها در حالت‌هایی با ۳۰ ویژگی می‌باشد. نکته قابل توجه این است که با افزایش تعداد ویژگی‌ها و کمک بیشتری که به طبقه‌بندی کننده‌ها از نظر بهبود غنای الگوهای ورودی می‌شود، همه طبقه‌بندی کننده‌ها به لحاظ عملکردی رشد بسیار خوبی دارند، به جزء درخت تصمیم. در حالت اول بعد از ماشین بردار پشتیبان، تقریباً دومین طبقه‌بندی کننده‌ها مناسب بوده است و بالعکس

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

در حالت دوم به مقدار بسیار کمی در مقایسه با دیگر روش‌ها بهبود یافته است. البته کاملاً رفتار قابل انتظاری است، چون اساساً استراتژی‌های درخت تصمیم، مناسب مسائلی با ویژگی‌های کمتر هستند و به صورت نمایی با بزرگ شدن مسئله بزرگ می‌شوند. نکته دیگر برتری قابل محسوس ماشین بردار پشتیبان در همه معیارهای ارزیابی عملکرد بر سایر طبقه‌بندی کننده‌ها در حالت دوم می‌باشد. این مسئله هم قابل پیش‌بینی بوده است. چون هر چه ابعاد الگوهای ورودی افزایش پیدا کند، ماشین بردار پشتیبان خصوصا نسخه‌های kernel-based آن، بهتر عمل می‌کنند.

جدول ۳: نرخ دسته‌بندی برای هر دسته‌بندی کننده با استفاده از ۱۵ ویژگی با اعمال فیلتر

الگوریتم دسته‌بندی	نرخ دسته بندی صحیح (CCR)
Multilayer Perceptron	۸۱/۸۲۴۶
Radial Basis Functions	۸۲/۳۸۱
Naive Bayes Classifier	۷۸/۰۹۵۲
Decision tree (C4.5)	۷۹/۵۲۳۸
Support Vector Machines	۸۴/۲۸۵۷

جدول ٤: ارزیابی عملکرد هر دسته‌بندی کننده با استفاده از ۱۵ ویژگی با اعمال فیلتر

الگوریتم	Precision	Recall	F-Score	Specificity	Sensitivity	FP Rate	ROC Area	Model Build Time
MLP	۰/۸۰۶	۰/۸۱۴	۰/۸۰۷	۰/۶۴۸	۰/۸۰۷	۰/۳۵۲	۰/۸۴۳	۱/۶۴
RBF	۰/۸۱۶	۰/۸۲۴	۰/۸۱۶	۰/۶۵۲	۰/۸۱۶	۰/۳۴۸	۰/۸۰۱	۰/۰۵
Naïve Bayes	۰/۷۶۶	۰/۷۸۱	۰/۷۶۸	۰/۵۶۸	۰/۷۶۸	۰/۴۳۲	۰/۷۹۵	~۰
C4.5 Algorithm	۰/۷۹۶	۰/۷۹۵	۰/۷۹۶	۰/۶۸۷	۰/۷۹۶	۰/۳۱۳	۰/۷۵۴	۰/۰۳
SVM	۰/۸۳۸	۰/۸۴۳	۰/۸۳۳	۰/۶۵۹	۰/۸۳۳	۰/۳۴۱	۷۵۱۸۰	۰/۰۸

جدول ۵: نرخ دسته بندی برای هر دسته‌بندی کننده با استفاده از ۳۰ ویژگی با اعمال فیلتر

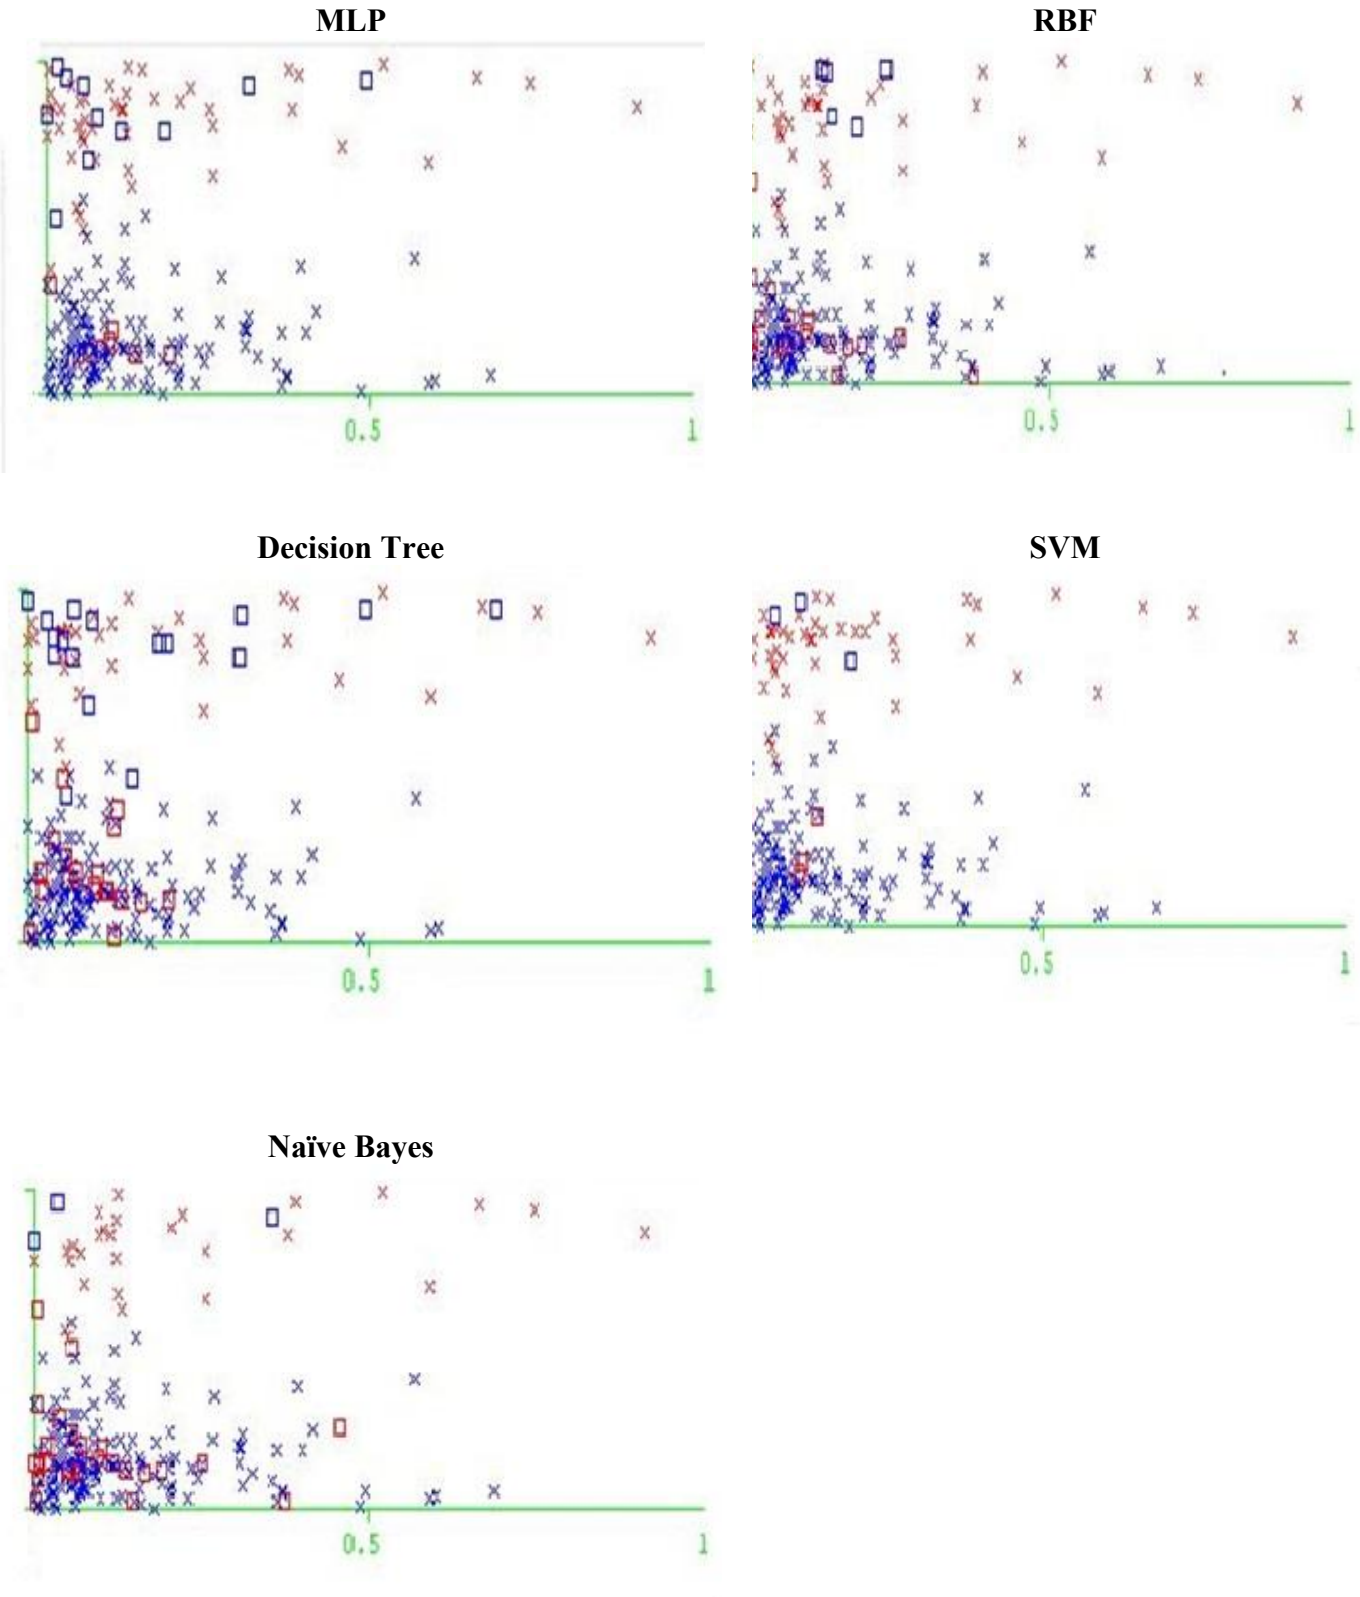
الگوریتم دسته بندی	نرخ دسته بندی صحیح (CCR)
MultiLayer Perceptron	۹۰/۴۷۶۲
Radial Basis Functions	۸۸/۰۹۵۲
Naive Bayes Classifier	۸۵/۲۳۸۱
Decision tree (C4.5)	۸۱/۴۲۸۶
Support Vector Machines	۹۵/۲۳۸۱

جدول ٦: ارزیابی عملکرد هر دسته‌بندی کننده با استفاده از ۳۰ ویژگی با اعمال فیلتر

الگوریتم	Precision	Recall	F-Score	Specificity	Sensitivity	FP Rate	ROC Area	Model Build Time
MLP	۰/۹۰۶	۰/۹۰۵	۰/۹۰۵	۰/۸۶۳	۰/۹۰۵	۰/۱۳۷	۰/۹۳۱	۵/۱۶
RBF	۰/۸۸۱	۰/۸۸۱	۰/۸۷۵	۰/۷۲۹	۰/۸۸۱	۰/۲۷۱	۰/۸۶۳	۰/۲
Naïve Bayes	۰/۸۵۹	۰/۸۵۲	۰/۸۳۷	۰/۶۲۸	۰/۸۵۲	۰/۳۷۲	۰/۸۷۹	۰/۰۲
C4.5 Algorithm	۰/۸۱	۰/۸۱۴	۰/۸۱۱	۰/۶۸۲	۰/۸۱۴	۰/۳۱۸	۰/۷۵۸	۰/۱۷
SVM	۰/۹۵۲	۰/۹۵۲	۰/۹۵۲	۰/۹۱۵	۰/۹۵۲	۰/۰۸۵	۰/۹۳۳	۰/۱۴

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

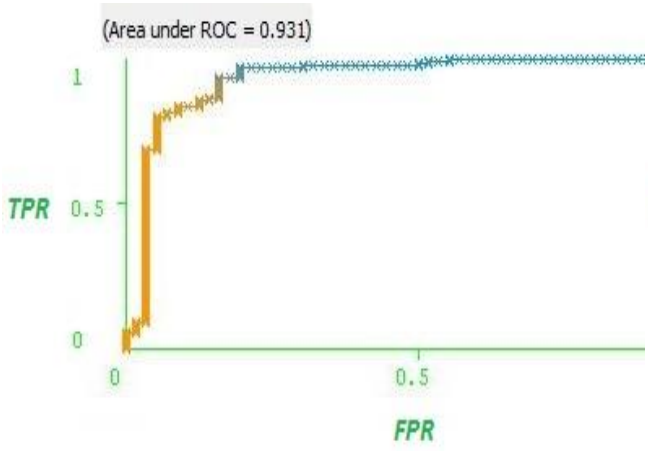
مجله انفورماتیک سلامت و زیست پزشکی دوره یازدهم، شماره چهارم، سال ۱۴۰۳، ص ۳۲۲-۳۰۶
doi: 10.34172/jhbmi.2025.03
مرکز تحقیقات انفورماتیک پزشکی، دانشگاه علوم پزشکی کرمان



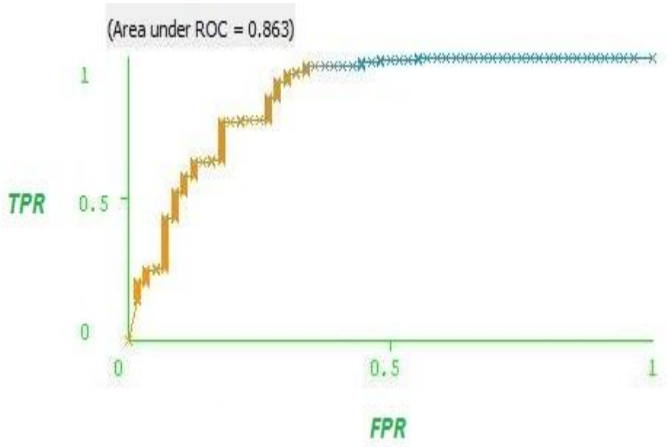
شکل ۵: پراکندگی الگوها با خطای دسته‌بندی‌کننده (کاراکترهای آبی و قرمز به ترتیب موارد بیمار و عادی هستند)

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

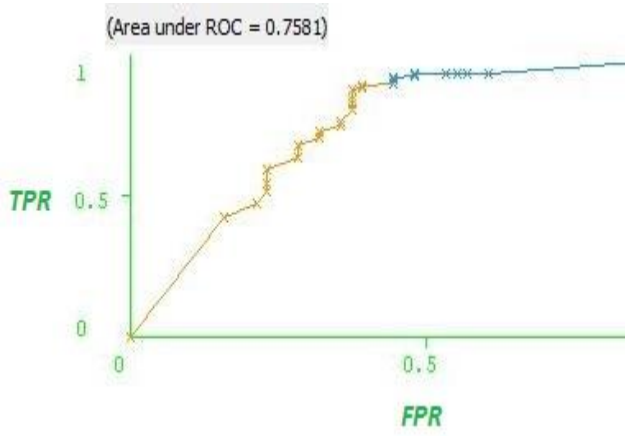
MLP



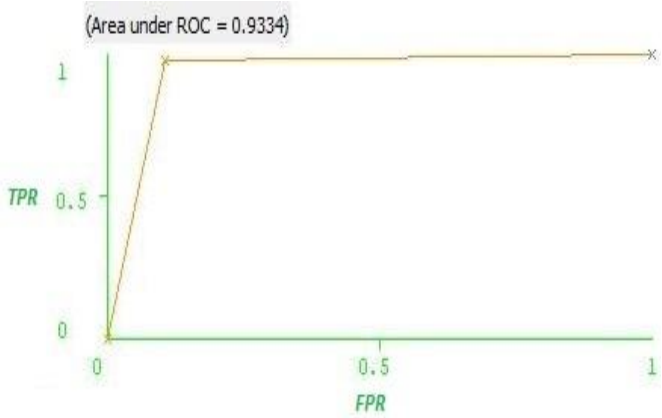
RBF



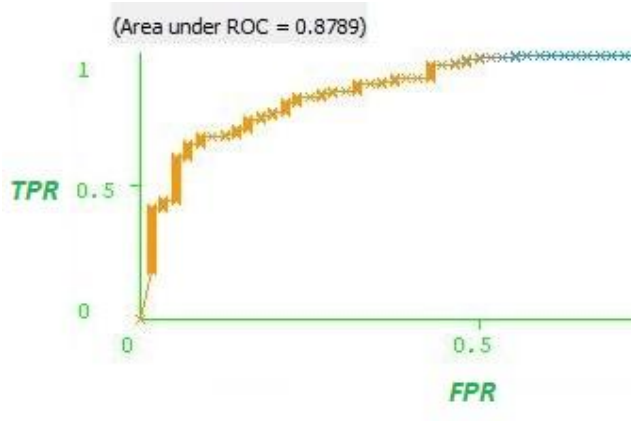
Decision Tree



SVM



Naïve Bayes



شکل ٦: منحنی‌های ROC هر دسته بندی کننده

[Downloaded from jhbmi.ir on 2026-11-25]

[DOI: 10.34172/jhbmi.2025.03]

بحث و نتیجه گیری

در این مطالعه، یک مدل یکپارچه برای تشخیص ضایعات پیش‌سرطانی و سرطانی دهان ارائه شد که شامل مراحل پیش‌پردازش تصاویر، استخراج ویژگی‌ها و طبقه‌بندی با استفاده از الگوریتم‌های یادگیری ماشین بود. نتایج نشان داد که مدل پیشنهادی با استفاده از الگوریتم ماشین بردار پشتیبان به دقت ۹۵/۲۳٪ در تشخیص ضایعات دست یافت. این دقت در مقایسه با سایر الگوریتم‌های مورد استفاده (شبکه عصبی چندلایه، توابع پایه شعاعی، درخت تصمیم و دسته‌بندی‌کننده بیزی) بالاتر بود. عملکرد برتر SVM را می‌توان به چند عامل کلیدی نسبت داد:

توانایی در مدیریت داده‌های با ابعاد بالا: به دلیل استفاده از کرنل‌های غیرخطی (مانند RBF)، توانسته است داده‌ها را در فضای ویژگی‌های پیچیده به خوبی جدا کند. این ویژگی به ویژه در داده‌های پزشکی که اغلب دارای ابعاد بالا و غیرخطی هستند، بسیار مفید است.

مقاومت در برابر بیش‌برازش: به دلیل استفاده از حاشیه بیشینه (Max Margin)، کمتر در معرض بیش‌برازش قرار می‌گیرد. این ویژگی باعث می‌شود مدل بتواند به داده‌های جدید نیز تعمیم خوبی داشته باشد.

تنظیم پارامترهای SVM: با تنظیم پارامترهای مناسب مانند پارامتر کرنل و هزینه (C)، توانسته است تعادل مناسبی بین دقت و تعمیم‌پذیری ایجاد کند.

در عین حال استفاده از SVM محدودیت‌هایی نیز دارد. نظیر این که SVM به دلیل پیچیدگی محاسباتی بالا، به ویژه در داده‌های با حجم زیاد، ممکن است زمان محاسباتی بیشتری نیاز داشته باشد. همچنین، انتخاب کرنل مناسب نیاز به دانش و تجربه دارد. شبکه عصبی MLP، با دقت ۹۰/۴۷٪ عملکرد خوبی داشت. این الگوریتم به دلیل ساختار لایه‌ای خود، توانست الگوهای پیچیده‌تری را در داده‌ها شناسایی کند؛ اما با این وجود، MLP به دلیل نیاز به تنظیم دقیق پارامترها (مانند تعداد لایه‌ها و نرون‌ها) و احتمال بیش‌برازش، نتوانست به دقت SVM برسد. همچنین، آموزش MLP به داده‌های بیشتری نیاز دارد تا بتواند به خوبی تعمیم یابد. طبقه‌بندی کننده RBF، با دقت ۸۸/۰۹٪ عملکرد متوسطی داشت، اما به دلیل حساسیت به پارامترهای اولیه (مانند تعداد مراکز خوشه‌ها)، نتوانست به دقت SVM برسد. این الگوریتم به دلیل وابستگی به انتخاب مراکز خوشه‌ها، ممکن است در داده‌های با توزیع ناهمگن عملکرد ضعیف‌تری داشته باشد. درخت تصمیم (C4.5)، با دقت ۴۲/۸۱٪ ضعیف‌ترین عملکرد را در میان الگوریتم‌های مورد استفاده داشت. این الگوریتم برای داده‌های با ابعاد پایین مناسب‌تر است و با افزایش تعداد ویژگی‌ها، عملکرد آن کاهش می‌یابد. درخت تصمیم به دلیل ساختار سلسله‌مراتبی خود، ممکن است در داده‌های با ابعاد بالا دچار بیش‌برازش شود. همچنین، این الگوریتم به تغییرات کوچک در داده‌ها حساس است و ممکن است نتواند به خوبی تعمیم یابد. دسته‌بندی‌کننده بیزی، این الگوریتم با دقت ۸۵/۲۳٪ عملکرد متوسطی داشت. دسته‌بندی‌کننده بیزی به دلیل فرضیات ساده‌ای که در مورد توزیع داده‌ها دارد، نتوانست به دقت الگوریتم‌های دیگر برسد. این الگوریتم فرض می‌کند که ویژگی‌ها مستقل از یکدیگر هستند، در حالی که در داده‌های واقعی این فرضیه ممکن است برقرار نباشد. این موضوع می‌تواند دقت مدل را کاهش دهد.

نقاط قوت مدل پیشنهادی

۱- دقت بالا: مدل پیشنهادی با استفاده از SVM به دقت ۹۵/۲۳٪ دست یافت که نشان‌دهنده توانایی بالای این الگوریتم در تشخیص ضایعات پیش‌سرطانی و سرطانی دهان است. این دقت در مقایسه با مطالعات مشابه، بسیار قابل توجه است.

۲- یکپارچگی: این مدل از مرحله پیش‌پردازش تصاویر تا طبقه‌بندی نهایی را به صورت یکپارچه انجام می‌دهد و نیاز به دخالت دستی را کاهش می‌دهد. این ویژگی باعث می‌شود مدل برای استفاده در محیط‌های بالینی عملی‌تر باشد.

۳- قابلیت تعمیم: با استفاده از اعتبارسنجی متقابل ۱۰-fold، مدل پیشنهادی توانایی تعمیم به داده‌های جدید را دارد. این موضوع نشان می‌دهد که مدل نه تنها بر روی داده‌های آموزشی، بلکه بر روی داده‌های آزمون نیز عملکرد خوبی دارد.

۴- استفاده از الگوریتم‌های متنوع: مقایسه چندین الگوریتم یادگیری ماشین امکان انتخاب بهترین روش را فراهم کرد. این رویکرد مقایسه‌ای به درک بهتر نقاط قوت و ضعف هر الگوریتم کمک می‌کند.

نقاط ضعف مدل پیشنهادی

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

۱- وابستگی به کیفیت تصاویر: عملکرد مدل به شدت به کیفیت تصاویر ورودی وابسته است. تصاویر با کیفیت پایین یا نویز زیاد می‌توانند دقت مدل را کاهش دهند. برای بهبود این موضوع، پیشنهاد می‌شود از روش‌های پیش‌پردازش پیشرفته‌تر مانند حذف نویز و افزایش کنتراست استفاده شود.

۲- نیاز به داده‌های بیشتر: با وجود استفاده از ۲۱۰ تصویر، حجم داده‌ها برای آموزش مدل‌های پیچیده‌تر مانند شبکه‌های عصبی عمیق ممکن است کافی نباشد. جمع‌آوری داده‌های بیشتر و متنوع‌تر می‌تواند به بهبود عملکرد مدل کمک کند.

یافته‌های این پژوهش با نتایج چندین مطالعه پیشین در حوزه تشخیص بیماری‌های دهانی همسو است. برای مثال، مطالعه López-Cortés و همکاران [۲۱] نیز نشان داد که SVM به دلیل توانایی آن در مدیریت داده‌های با ابعاد بالا، یکی از بهترین الگوریتم‌ها برای تشخیص بیماری‌های دهانی است. با این حال، در مطالعه Panigrahi و همکاران [۲۲]، شبکه‌های عصبی چندلایه عملکرد بهتری نسبت به SVM نشان دادند، که این تفاوت ممکن است به دلیل تفاوت در نوع داده‌ها یا روش‌های استخراج ویژگی‌ها و یا اساساً نوع مسئله دسته‌بندی باشد. در پژوهش حاضر، با استفاده از الگوریتم SURF برای استخراج ویژگی‌ها و K-means برای انتخاب ویژگی‌های بهینه، دقت SVM به میزان قابل توجهی بهبود یافت. این موضوع نشان می‌دهد که انتخاب روش‌های مناسب برای پیش‌پردازش داده‌ها و استخراج ویژگی‌ها می‌تواند تأثیر بسزایی در عملکرد نهایی مدل داشته باشد. علاوه بر این، نتایج این پژوهش از این جهت حائز اهمیت است که برای اولین بار یک فرآیند تشخیصی یکپارچه از تصویربرداری تا دسته‌بندی را با دقت بالا ارائه می‌دهد، که گامی مهم در جهت توسعه سیستم‌های هوشمند تشخیص بیماری‌های دهانی محسوب می‌شود.

در این مطالعه یک سیستم یکپارچه تشخیصی بیماری‌های(شامل پیش‌سرطانی و سرطانی) دهانی از ابتدایی‌ترین فاز آن یعنی برداشت یک تصویر از بیمار تا دسته‌بندی موردهای بیمار از سالم پیشنهاد شده است. در این پژوهش برای نخستین بار تصاویر متعددی از ضایعات پیش‌سرطانی و سرطانی دهان تهیه شده و پس از استخراج ویژگی‌های زیاد از تصاویر با استفاده از الگوریتم Surf به کمک الگوریتم خوشه‌بندی K-means، مناسب‌ترین ویژگی‌ها انتخاب شدند. سپس در یک رویکرد تحلیلی مقایسه‌ای و در عین حال یکپارچه، کار دسته‌بندی بر روی آن‌ها صورت گرفت. برتری روش ماشین بردار پشتیبان بر سایر روش‌ها به وضوح مشهود است. درصد صحت دسته‌بندی ۹۵/۲۳۸۱ توسط SVM با اعتبارسنجی متقابل 10-fold استحصال گردید. مدل پیشنهادی جزء معدود پژوهش‌هایی در حوزه بیماری‌های دهان می‌باشد که یک فرآیند تشخیصی یکپارچه را پیاده کرده است. مدل پیشنهادی با استفاده از الگوریتم SVM به دقت بالایی در تشخیص ضایعات پیش‌سرطانی و سرطانی دهان دست یافت. این مدل می‌تواند به عنوان یک ابزار کمکی در کنار متخصصان پزشکی برای تشخیص سریع‌تر و دقیق‌تر این ضایعات استفاده شود. با این حال، برای بهبود عملکرد مدل، پیشنهاد می‌شود در آینده از روش‌های یادگیری عمیق و حجم بیشتری از داده‌ها استفاده شود. همچنین، بهبود کیفیت تصاویر ورودی و کاهش نویز می‌تواند به افزایش دقت مدل کمک کند. علاوه بر این، استفاده از تکنیک‌های افزایش داده (Data Augmentation) و یادگیری انتقالی (Transfer Learning) می‌تواند به بهبود عملکرد مدل در داده‌های محدود کمک کند. براساس تحلیل‌های تجربی، می‌توان با اطمینان بالایی عنوان کرد، استفاده از سیستم تشخیصی پیشنهادی اگرچه نمی‌تواند جایگزین متخصصین متبحر شود؛ اما به عنوان یک ابزار امیدبخش با صحت و دقت بالا در تشخیص و درمان بیماری‌های دهان می تواند مورد استفاده قرار گیرد. البته بدیهی است نیاز به مطالعه بیشتر با ایجاد پایگاه جامع‌تر تصاویر و داده‌ها در زمینه بیماری‌های دهان و ارتقاء و آموزش بیشتر سیستم‌های هوشمند وجود دارد.

تعارض منافع

ندارد.

حمایت مالی

برای انجام این پژوهش حمایت مالی از هیچ نهادی صورت نگرفته است.

[Downloaded from jhbmi.ir on 2026-11-25]

[DOI: 10.34172/jhbmi.2025.03]

کد اخلاق

این پژوهش در کمیته اخلاق دانشگاه علوم پزشکی کرمان با کد IR.KMU.REC.1404.153 تصویب گردید.

مشارکت نویسندگان

نویسنده اول: طراحی ایده پژوهش، روش‌شناسی مطالعه، جمع‌آوری داده‌ها، نرم‌افزار/کد نویسی، نوشتن متن اولیه، اعتبارسنجی نتایج.
نویسنده دوم: پاکسازی و آماده‌سازی داده‌ها، ویرایش و بهبود متن، تحلیل داده‌ها، تهیه نمودار/تصاویر.

References

[1]. Sarafi Nejad A. Knowledge Discovery and Data Mining in Medical Sciences, a Review of the Requirements for Applied Researches. Journal of Health and Biomedical Informatics 2023;10(2):198-200. [In Persian]
[2]. Nabizadeh A. Artificial Intelligence in Healthcare. Journal of Health and Biomedical Informatics 2022; 9(3): 193-5. [In Persian]
[3]. Hajieslam F, Javanmard Z. Investigating the Role of Clinical Decision Support Systems in Reducing Medical Errors. Journal of Health and Biomedical Informatics 2023;10(1):82-90. [In Persian]
[4]. Yardimci A. Soft computing in medicine. Applied Soft Computing 2009;9(3):1029-43. https://doi.org/10.1016/j.asoc.2009.02.003
[5]. Zuo WL, Wang ZY, Liu T, Chen HL. Effective detection of Parkinson's disease using an adaptive fuzzy k-nearest neighbor approach. Biomedical Signal Processing and Control 2013;8(4):364-73. https://doi.org/10.1016/j.bspc.2013.02.006
[6]. Maghsoudi R, Mirzarezaee M, Sadeghi M, Najar-Araabi B. Development of a Pharmacogenomics Model based on Support Vector Regression with Optimal Features Selection Approach to Determine the Initial Therapeutic Dose of Warfarin Anticoagulant Drug. Journal of Health and Biomedical Informatics 2023;9(4):209-29. [In Persian]
[7]. Tobias MA, Nogueira BP, Santana MC, Pires RG, Papa JP, Santos PS. Artificial intelligence for oral cancer diagnosis: What are the possibilities?. Oral Oncology 2022;134:106117.
[8]. Azizi A, Mohammadi Khorasani M. Designing and assessment of decision support system (computerized software) in diagnosis of jaws' bony lesions. Journal of Dental School 2009; 27(1): 31-5. [In Persian]
[9]. Rafati H, Molavi Taleghani Y. Feasibility study for the establishment of Telemedicine: a review study and a suggestion for Iran. Journal of Health and Biomedical Informatics 2019;5(4):507-19. [In Persian]
[10]. Neville BW, Damm DD, Allen CM, Chi AC. Oral and maxillofacial pathology-E-Book. Elsevier Health Sciences; 2023.
[11]. Keser G, Bayrakdar İŞ, Pekiner FN, Çelik Ö, Orhan K. A deep learning algorithm for classification of oral lichen planus lesions from photographic images: A retrospective study. Journal of Stomatology, Oral And Maxillofacial Surgery 2023;124(1):101264. https://doi.org/10.1016/j.jormas.2022.08.007
[12]. Achararit P, Manaspon C, Jongwannasiri C, Phattarataratip E, Osathanon T, Sappayatosok K. Artificial intelligence-based diagnosis of oral lichen planus using deep convolutional neural networks. European Journal of Dentistry 2023;17(04):1275-82. doi: 10.1055/s-0042-1760300
[13]. Adeoye J, Koohi-Moghadam M, Choi SW, Zheng LW, Lo AW, Tsang RK, et al. Predicting oral cancer risk in patients with oral leukoplakia and oral lichenoid mucositis using machine learning. Journal of Big Data 2023;10(1):39.
[14]. Xu Z, Han Q, Yang D, Li Y, Shang Q, Liu J, et al. Automatic detection of image-based features for immunosuppressive therapy response prediction in oral lichen planus. Frontiers in Immunology 2022;13:942945. https://doi.org/10.3389/fimmu.2022.942945
[15]. Idrees M, Farah CS, Shearston K, Kujan O. A machine-learning algorithm for the reliable identification of oral lichen planus. Journal of Oral Pathology & Medicine 2021;50(9):946-53. **https://doi.org/10.1111/jop.13226**
[16]. Alhazmi A, Alhazmi Y, Makrami A, Masmali A, Salawi N, Masmali K, Patil S. Application of artificial intelligence and machine learning for prediction of oral cancer risk. Journal of Oral Pathology & Medicine 2021;50(5):444-50.
[17]. Fassihi N, Shanbehzadeh J, Sarrafzadeh H, Ghasemi E. Melanoma diagnosis by the use of wavelet analysis based on morphological operators. Proceedings of the International MultiConference of Engineers and Computer Scientists. 2011, Mar 16 - 18; Hong Kong: IMECS; 2011.
[18]. Maghsoudi R, Bagheri A, Maghsoudi MT. Diagnosis prediction of lichen planus, leukoplakia and oral squamous cell carcinoma by using an intelligent system based on artificial neural networks. Journal of Dentomaxillofacial 2013;2(2):1-8. doi: 10.18869/acadpub.3dj.2.2.1

[Downloaded from jhbmi.ir on 2026-11-25]
[DOI: 10.34172/jhbmi.2025.03]

[19]. Rosado P, Lequerica-Fernández P, Villallaín L, Peña I, Sanchez-Lasheras F, De Vicente JC. Survival model in oral squamous cell carcinoma based on clinicopathological parameters, molecular markers and support vector machines. Expert Systems with Applications 2013;40(12):4770-6. https://doi.org/10.1016/j.eswa.2013.02.032
[20]. Bay H, Tuytelaars T, Van Gool L. SURF: Speeded Up Robust Features. in Computer Vision–ECCV 2006: 9th European Conference on Computer Vision, Graz, Austria, May 7-13, 2006. Proceedings, Part I 9. 2006. Springer.
[21]. López-Cortés XA, Matamala F, Venegas B, Rivera C. Machine-learning applications in oral cancer: A systematic review. Applied Sciences 2022;12(11):5715.
[22]. Panigrahi S, Nanda BS, Swarnkar T. Comparative analysis of machine learning algorithms for histopathological images of oral cancer. InAdvances in Distributed Computing and Machine Learning: Proceedings of ICADCML Singapore: Springer; 2022. p. 318-27. doi::10.1007/978-981-16-4807-6_31

[Downloaded from jhbmi.ir on 2026-11-25]

[DOI: 10.34172/jhbmi.2025.03]