



Selection of Effective Features from Raw US RF Signals to Enhance Intelligent Breast Lesion Classification using Machine Learning

Arab, Mahsa¹ / Fallah, Ali^{2*} / Rashidi, Saeid³ / Mehdizadeh Dastjerdi, Maryam⁴ / Ahmadinejad, Nasrin⁵

¹ - Ph.D. Candidate, Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

² - Associate Professor, Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

³ - Assistant Professor, Biomedical Engineering Group, Medical Sciences and Technologies Department, Islamic Azad University, Science and Research Branch, Tehran, Iran

⁴ - Ph.D., Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

⁵ - Associate Professor, Radiology-Medical Imaging Center, Cancer Research Institute, Imam Khomeini Hospital Advanced Diagnostic and Interventional Radiology Research Center, Medical Sciences and Technologies Department, Tehran University of Medical Sciences, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2024.2012148.1864

Received: 4 October 2023

Revised: 27 December 2023

Accepted: 5 January 2024

KEYWORDS

Radio Frequency

Ultrasound

B-Mode Images

Time Series

Classification

Machine Learning

Breast Lesions

ABSTRACT

Breast cancer stands as the most prevalent form of cancer among women, with over 80% of early-stage breast abnormalities being benign. Timely detection is therefore crucial for prompt intervention. Ultrasound Radio Frequency (US RF) signals represent a non-invasive, and real-time screening method for breast cancer, offering advantages in tissue differentiation and cost-effectiveness without requiring additional equipment. This research aims to present an intelligent approach for the classification of benign, suspicious, and malignant breast lesions based on effective features extracted from the time series. The dataset, registered as USRFTS, comprises 170 instances recorded from 88 patients. The proposed methodology encompasses four key phases: pre-processing, feature extraction, feature selection, and classification. In the pre-processing phase, B-mode images are reconstructed from US RF time series, and a radiologist manually selects the Region of Interest (ROI) in each image. Subsequently, diverse features in the time and frequency domains are extracted from each ROI during the feature extraction stage. The ant colony method is employed for the selection of impactful features. The dataset is then subjected to evaluation using classifiers such as Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Decision Tree (DT), Linear Discriminant Analysis (LDA), and a reference classification method (RCM). The results demonstrate a maximum classification accuracy of 94.95% for two classes and 93.33% for three classes.

*Corresponding Author


Address: Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

Postal Code: 11365-9567

E-Mail: afallah@aut.ac.ir

Tel: +98-21-64542365





انتخاب ویژگی‌های موثر سیگنال‌های فرکانس رادیویی اولتراسوند خام به منظور بهبود طبقه‌بندی هوشمند ضایعات پستانی با استفاده از یادگیری ماشین

عرب، مهسا^۱ / فلاح، علی^{۲*} / رشیدی، سعید^۳ / مهدی‌زاده دستجردی، مریم^۴ / احمدی‌نژاد، نسرین^۵

- ^۱ - دانشجوی دکتری، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران
- ^۲ - دانشیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران
- ^۳ - استادیار، گروه مهندسی پزشکی، دانشکده‌ی علوم و فناوری‌های پزشکی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران
- ^۴ - دکتری، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران
- ^۵ - دانشیار، مرکز تصویربرداری پزشکی-رادیولوژی، پژوهشکده‌ی سرطان، مرکز تحقیقات رادیولوژی پیشرفته‌ی تشخیصی و مداخله‌ای بیمارستان امام خمینی، دانشگاه علوم پزشکی تهران، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2012148.1864

پذیرش: ۱۵ دی ۱۴۰۲

بازنگری: ۶ دی ۱۴۰۲

ثبت در سامانه: ۱۲ مهر ۱۴۰۲

واژه‌های کلیدی	چکیده
فرکانس رادیویی اولتراسوند تصاویر B-Mode سری زمانی طبقه‌بندی یادگیری ماشین ضایعات پستان	سرطان پستان رایج‌ترین نوع سرطان در زنان است. بیش از ۸۰٪ ناهنجاری‌های پستان در مراحل اولیه خوش‌خیم هستند. بنابراین تشخیص زودهنگام مهم‌ترین چالش برای درمان به موقع است. یکی از روش‌های غیرتهاجمی و زمان‌واقعی برای غربال‌گری سرطان پستان استفاده از سیگنال‌های فرکانس رادیویی اولتراسوند (US RF) است. این روش علاوه بر تمایز بافتی و مقرون به صرفه بودن، در مقایسه با روش‌های دیگر نیازی به تجهیزات تکمیلی ندارد. این پژوهش با هدف ارائه‌ی رویکردی هوشمند برای طبقه‌بندی ضایعات خوش‌خیم، مشکوک و بدخیم پستان بر اساس ویژگی‌های موثر استخراج شده از سری زمانی US RF صورت گرفته است. مجموعه‌ی داده‌ی US RF ثبت شده با عنوان USRFTS شامل ۱۷۰ داده از ضایعات مذکور بوده که از ۸۸ بیمار به دست آمده است. روش پیشنهادی در این تحقیق شامل چهار بخش اصلی پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی است. در مرحله‌ی پیش‌پردازش پس از بازسازی تصاویر B-mode از سری‌های زمانی US RF ثبت شده، ناحیه‌ی دارای ضایعه (ROI) در هر تصویر B-mode توسط پرتوشناس به صورت دستی انتخاب شده است. در ادامه ویژگی‌های مختلف حوزه‌های زمان و فرکانس در مرحله‌ی استخراج ویژگی از هر ROI استخراج شده و پس از آن ویژگی‌های موثر با استفاده از روش کلونی مورچه انتخاب شده است. در نهایت دادگان با استفاده از طبقه‌بندهای ماشین بردار پشتیبان (SVM)، K-نزدیک‌ترین همسایه (KNN)، درخت تصمیم (DT)، تجزیه‌ی تشخیص خطی (LDA) و هم‌چنین روش طبقه‌بندی با مرجع (RCM) مورد ارزیابی قرار گرفته است. با توجه به نتایج به دست آمده بیشینه‌ی صحت طبقه‌بندی دوکلاسه و سه‌کلاسه به ترتیب برابر با ۹۴/۹۵٪ و ۹۳/۳۳٪ ارزیابی شده است.

*نویسنده‌ی مسئول

نشانی: گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

تلفن: ۶۴۵۴۲۳۶۵-۲۱-۹۸+

پست الکترونیکی: afallah@aut.ac.ir

کد پستی: ۹۵۶۷-۱۱۳۶۵



۱- مقدمه

سرطان یکی از علل اصلی مرگ‌ومیر در سراسر جهان است [۱]. سرطان پستان^۱ یکی از انواع سرطان‌های شایع در بین زنان ایرانی بوده به طوری که ۱/۲۸٪ از کل موارد این بیماری را به خود اختصاص داده است [۲]. تشخیص و درمان زودهنگام، بهترین و مناسب‌ترین روش برای کاهش مرگ‌ومیر ناشی از سرطان پستان است. تشخیص خوش‌خیم^۲ یا بدخیم^۳ بودن نوع ناهنجاری‌های بافت پستان بدون انجام روش نمونه‌برداری^۴ که در گروه روش‌های تهاجمی قرار می‌گیرد ممکن نیست. روش‌هایی مانند معاینه‌ی بالینی پستان^۵ (CBE) و معاینه‌ی خودآزمایی سینه^۶ (BSE) دارای نرخ مثبت کاذب^۷ بالایی هستند [۳]. بنابراین به نظر می‌رسد که ارائه‌ی روشی کم‌هزینه، غیرتهاجمی و غیریون‌زا با صحت و دقت بالا برای تشخیص و تفکیک ناهنجاری‌های بافت پستان امری ضروری است.

از جمله دیگر روش‌های تشخیص سرطان پستان ماموگرافی، تصویربرداری تشدید مغناطیسی^۸ (MRI)، اولتراسوند^۹ (US) و دادگان فرکانس رادیویی اولتراسوند^{۱۰} (US RF) است. از مزیت‌های اصلی US می‌توان به هزینه‌ی کم و زمان واقعی بودن آن اشاره کرد. در مقابل، اشکالات اصلی US، تصاویر B-mode با تباين^{۱۱} کم، اثر نویز لکه‌ای^{۱۲} و تغییرپذیری نسبت به کاربر است [۴-۷]. برای غلبه بر این محدودیت‌ها تحقیقاتی در زمینه‌ی روش‌های تشخیصی مبتنی بر رایانه^{۱۳} (CAD) برای تشخیص سرطان سینه انجام شده است.

در مقاله‌ی [۸] از نقشه‌های خودسازمان‌دهی و ویژگی‌های US بافت برای طبقه‌بندی ضایعات پستان استفاده شده است. در مقاله‌ی [۹] روشی برای طبقه‌بندی ضایعات پستان بر اساس بافت و ویژگی‌های طیفی تعمیم یافته همراه با تجزیه و تحلیل متمایز خطی^{۱۴} (LDA) و درجه‌ی دوم^{۱۵} ارائه شده است. در مقاله‌ی [۱۰] از یک آرایه‌ی عصبی مصنوعی^{۱۶} (ANN) برای افتراق ضایعات پستان با در نظر گرفتن ۵ ویژگی ریخت‌شناسی مرتبط با شکل، خطوط و تیرگی هر ضایعه استفاده شده است.

در مقالات [۱۱-۱۳] روش‌های تجزیه و تحلیل جدیدی مبتنی بر سری زمانی US RF برای طبقه‌بندی بافت‌ها پیشنهاد شده است. در مقاله‌ی [۳] با در نظر گرفتن ۲۹ ویژگی منحصربه‌فرد و سپس طبقه‌بندی آن‌ها به دو کلاس خوش‌خیم و بدخیم با استفاده از طبقه‌بند ماشین بردار پشتیبان^{۱۷} (SVM) نتایج مناسبی حاصل شده است. در این پژوهش بعد فراکتال^{۱۸} سری زمانی US RF به عنوان مناسب‌ترین مشخصه تعیین شده است. در مقاله‌ی [۱۴] طبقه‌بندی سیگنال US RF با استفاده از سه رویکرد مختلف شبکه‌ی عصبی پیچشی^{۱۹} (CNN) مورد بررسی قرار گرفته و بهترین صحت برابر با ۷۰٪ به دست آمده است.

در مقاله‌ی [۱۵] به منظور بهبود تشخیص نوع تومورهای پستان و کاهش نمونه‌برداری سوزنی غیرضروری برای ضایعات خوش‌خیم از روش استخراج ویژگی چندگانه^{۲۰} سیگنال‌های US RF استفاده شده است. طراحی روش پیشنهادی در این پژوهش بر مبنای شبیه‌سازی ادراک بینایی^{۲۱} ضایعات پستان مبتنی بر US با هدایت چهارچوب گزارش‌دهی و داده‌های تصویربرداری پستان^{۲۲} (BI-RADS) و با هدف افزایش دقت تشخیص بوده است. در این مقاله ۱۶ ویژگی متمایز از مجموعه‌ی ویژگی‌های ریخت‌شناسی و بافتی به منظور طبقه‌بندی ضایعات پستان بررسی شده و از ضریب همبستگی رتبه‌ی اسپیرمن^{۲۳} برای انتخاب ویژگی و بررسی رویکرد یادگیری نظارت شده‌ی استفاده شده است. پس از آن ویژگی‌ها با توجه به اهمیت آن‌ها در طبقه‌بندی ضایعات پستان رتبه‌بندی شده‌اند. نتایج این مطالعه نشان داده که ادغام این ۱۶ ویژگی، طبقه‌بندی موثر تومورهای پستان را تسهیل کرده و در نتیجه نمونه‌برداری‌های غیرضروری را کاهش می‌دهد.

برای تشخیص خودکار کلسیفیکاسیون^{۲۴} با استفاده از سیگنال‌های RF چندکاناله‌ی US، چهارچوب یادگیری عمیق جدیدی معرفی شده است [۱۶]. در این روش از معماری یادگیری عمیق مبتنی بر مدل YOLOv3 و ویژگی‌های مبتنی بر حافظه‌ی کوتاه‌مدت کانولوشن^{۲۵} (ConvLSTM) استفاده

^۱ Breast Cancer^۲ Benign^۳ Malignant^۴ Biopsy^۵ Clinical Breast Exam^۶ Breast Self-Examination^۷ False-Positive Rate^۸ Magnetic Resonance Imaging (MRI)^۹ Ultrasound (US)^{۱۰} Ultrasound Radio Frequency (US RF)^{۱۱} Contrast^{۱۲} Speckle Noise^{۱۳} Computer-Aided Diagnosis (CAD)^{۱۴} Linear Discriminant Analysis (LDA)^{۱۵} Quadratic^{۱۶} Artificial Neural Network (ANN)^{۱۷} Support Vector Machine (SVM)^{۱۸} Fractal Dimension^{۱۹} Convolutional Neural Network (CNN)^{۲۰} Multi-Feature^{۲۱} Visual Perception^{۲۲} Breast Imaging Reporting and Data System (BI-RADS)^{۲۳} Spearman's Rank Correlation Coefficient^{۲۴} Calcification^{۲۵} Convolutional Short-Term Memory (ConvLSTM)

ارائه شده توسط گار و هم‌کارانش از پتانسیل دادگان US RF به عنوان ورودی CNN-ها برای تسهیل برچسب‌گذاری تشخیصی موارد خوش‌خیم و بدخیم استفاده شده است [۱۹]. این رویکرد در مقایسه با تنها استفاده از تصاویر US، AUC را افزایش داده است. نتایج بر پیش‌رفت قابل توجهی که از طریق ادغام سیگنال‌های RF قابل دست‌یابی بوده تأکید کرده و راه‌کار امیدوارکننده‌ای برای بهبود طبقه‌بندی ضایعات پستان فراتر از محدودیت‌های تصویربرداری B-mode مرسوم ارائه داده است.

در ادامه در سال ۲۰۲۲ روش‌های یادگیری عمیق برای پیش‌بینی پاسخ درمان پستان بر مبنای نقشه‌های چندپارامتری QUS بررسی شده است [۲۰]. در این پژوهش رویکردی متمایز مبتنی بر دادگان US RF خام برای استخراج ویژگی‌های ذاتی پیشنهاد شده و سپس این اطلاعات با مرحله‌ی پیش‌پردازش^{۱۱} ترکیب شده است. ویژگی‌های تصاویر QUS حاصل به عنوان ورودی در ساختاری مبتنی بر CNN عمیق ادغام شده است. نتیجه‌ی این ترکیب به دست آمدن چهارچوب محوری موثری برای طبقه‌بندی و پیش‌بینی افراد به عنوان پاسخ‌دهنده یا پاسخ‌ندهنده به مداخلات درمانی تشخیصی بوده است.

در این مطالعه ابتدا مجموعه‌ای از سری‌های زمانی US RF درون‌تنی برای طبقه‌بندی ضایعات پستان به دو و سه کلاس ثبت شده است. پس از ثبت سیگنال‌های RF از توده‌های مختلف پستان، ویژگی‌های متمایز در حوزه‌های زمان، فرکانس و زمان-فرکانس استخراج شده است. در ادامه ویژگی‌های بهینه با استفاده از الگوریتم کلونی مورچه^{۱۲} استخراج شده است. در نهایت نیز ویژگی‌ها با استفاده از روش‌های مبتنی بر یادگیری ماشین دسته‌بندی شده است.

روش پیشنهادی برای طبقه‌بندی ضایعات پستان بر اساس سری‌های زمانی US RF با استفاده از رویکرد یادگیری ماشین به دلیل سریع بودن بر یادگیری عمیق برتری دارد. در حال حاضر از رویکردهای یادگیری عمیق به طور گسترده در تصویربرداری پزشکی استفاده شده و CNN-ها متداول‌ترین مدل‌های مورد استفاده برای کارهایی از جمله تقسیم‌بندی و طبقه‌بندی تصویر هستند [۲۱]. ویژگی‌هایی مانند دسترسی آسان به بسته‌های یادگیری عمیق و پتانسیل بسیار زیاد آن‌ها برای حمایت از تصمیم‌گیری‌ها در تشخیص و درمان سرطان،

شده است. در مقاله‌ی کیم و هم‌کارانش چهارچوب CNN برای تجزیه و تحلیل تصاویر US پستان با بهره‌گیری از تصاویر چندپارامتری تولید شده از سیگنال‌های RF ارائه شده است. در این پژوهش تصاویر آنتروپی و فاز که اطلاعات ساختاری خوبی را همراه با تصاویر B-mode متداول در بر دارند معرفی شده است. تصاویر B-mode به عنوان تصاویر پارامتری در حوزه‌ی زمان به کار گرفته شده است. همچنین تصویر تضعیف تخمینی^۱ ساخته شده از حوزه‌ی فرکانس سیگنال‌های RF به عنوان ویژگی طیفی مورد استفاده قرار گرفته است.

اثر بخشی تصویربرداری چندپارامتری سونوگرافی کمی^۲ (QUS) همراه با الگوریتم‌های طبقه‌بندی بدون نظارت برای اولین بار در توصیف نواحی درون توموری^۳ برای پیش‌بینی پاسخ تومور پستان به شیمی‌درمانی قبل از شروع درمان در سال ۲۰۲۱ مورد بررسی قرار گرفته است [۱۷]. تصاویر QUS از تومورهای سینه با استفاده از داده‌های US RF از بیماران مبتلا به سرطان پستان پیش‌رفته و برنامه‌ریزی شده برای شیمی‌درمانی نوآدجوانت^۴ پس از جراحی ایجاد شده است. از الگوریتم پیشینه‌سازی انتظار^۵ (EM) مدل مخفی میدان‌های تصادفی مارکوف^۶ (HMRF) برای شناسایی مناطق درون توموری متمایز در تصاویر QUS استفاده شده است. از یک روش انتخاب ویژگی چندمرحله‌ای نیز برای ساخت یک نشان‌گر زیستی^۷ QUS شامل چهار ویژگی برای پیش‌بینی پاسخ استفاده شده است. نتایج ارزیابی در یک مجموعه‌ی آزمایش مستقل نشان داده است که نشان‌گر زیستی توسعه یافته همراه با یک مدل درخت تصمیم^۸ (DT) با تقویت تطبیقی^۹ به عنوان طبقه‌بند می‌تواند پاسخ درمانی بیمار را قبل از درمان با دقت ۸۵/۴٪ پیش‌بینی کند. نتایج به دست آمده در این مطالعه پتانسیل تصاویر QUS همراه با روش‌های یادگیری بدون نظارت را در شناسایی مناطق درون توموری در سرطان پستان برای مشخص کردن پاسخ‌دهی آن به شیمی‌درمانی قبل از شروع درمان نشان داده است.

در سال ۲۰۲۲ در مقاله‌ی بایرا و هم‌کارانش از دادگان US RF به عنوان ورودی برای روش‌های مبتنی بر یادگیری عمیق استفاده شده و یک ناحیه‌ی زیرمنحنی^{۱۰} (AUC) برتر در مقایسه با استفاده از تصویربرداری B-mode برای طبقه‌بندی و تقسیم‌بندی ضایعات پستان به دست آمده است [۱۸]. در روش

^۷ Biomarker

^۸ Decision Tree

^۹ AdaBoost

^{۱۰} Area Under the Curve (AUC)

^{۱۱} Preprocessing

^{۱۲} Ant Colony

^۱ Estimated Attenuation Image

^۲ Quantitative Ultrasound (QUS)

^۳ Intra-Tumor

^۴ Neoadjuvant Chemotherapy

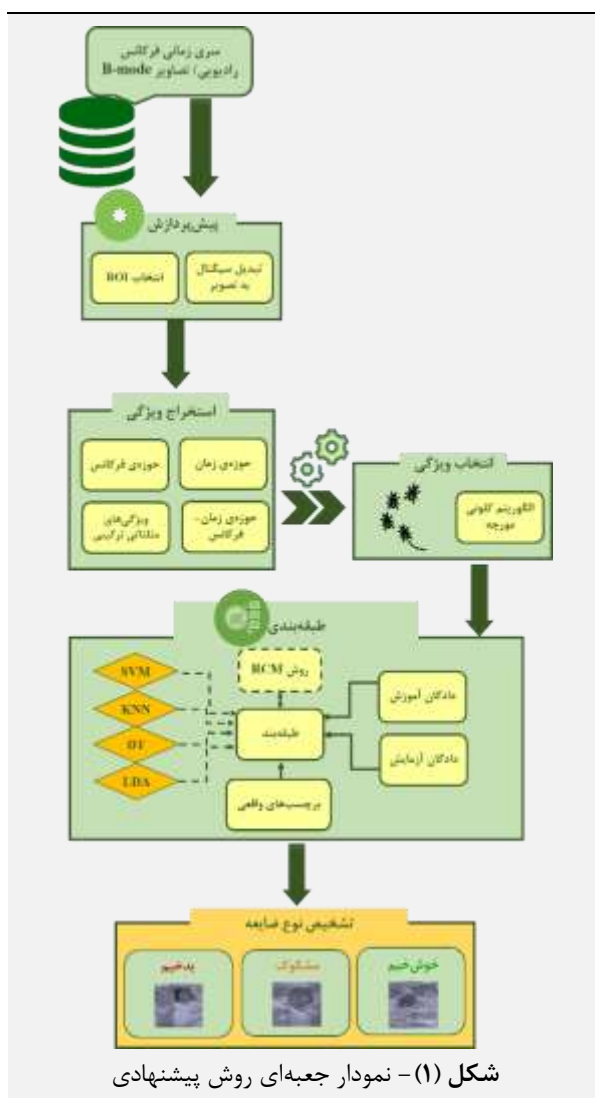
^۵ Expectation Maximization (EM)

^۶ Hidden Markov Random Field (HMRF)

در بخش بحث انجام شده است. در نهایت نیز به نتیجه‌گیری و ارائه‌ی پیشنهادها پرداخته شده است.

۲- مواد و روش‌ها

در این مقاله به طبقه‌بندی ضایعات خوش‌خیم، مشکوک^۴ و بدخیم پستان بر اساس معیار BI-RADS [۲۴، ۲۵] و مبتنی بر ویژگی‌های متعدد انتخاب شده از داده‌های US RF ثبت شده از آن‌ها در حوزه‌های مختلف زمان، فرکانس و زمان-فرکانس در یک چهارچوب یادگیری ماشین به منظور بهبود تشخیص نوع ضایعات پستان پرداخته شده است. نمودار جعبه‌ای روش پیشنهادی در شکل (۱) نمایش داده شده است.



منجر به پذیرش سریع مدل‌های یادگیری عمیق در زمینه‌ی تصویربرداری پزشکی شده است. با این حال مدل‌های یادگیری عمیق دارای چندین محدودیت بوده که باعث عدم استفاده از آن‌ها در این پژوهش شده است. اولاً مدل‌های یادگیری عمیق برای جلوگیری از برازش بیش از حد، به حجم عظیمی از داده‌های آموزشی نیاز دارند. ثانیاً اگر چه مدل‌های یادگیری عمیق نرخ‌های دقت بسیار بالایی دارند اما به دلیل ماهیت جعبه‌ی سیاه^۱ پیچیده‌ی آن‌ها، تفسیر مبانی منطقی تصمیم، بسیار دشوار است. اگر روش پیش‌بینی شفاف نباشد، پزشکان برای تکیه بر پیش‌بینی‌های CNN مردد هستند. در مقابل، روش‌های سنتی یادگیری ماشین کاملاً شفاف بوده و در آن‌ها پارامترهای الگوریتم را می‌توان به راحتی تغییر داد. علاوه بر این، مدل‌های یادگیری عمیق به شدت به کیفیت مجموعه‌ی داده‌های آموزشی وابسته هستند. در نهایت یکی از چالش‌های اصلی استفاده از یادگیری عمیق در تصویربرداری پزشکی، نیاز این روش‌ها به حجم بالایی از داده‌های پزشکی برجسب‌گذاری شده است. با توجه به این دلایل در این مقاله استفاده از روش‌های سنتی یادگیری ماشین به مدل‌های یادگیری عمیق برای طبقه‌بندی توده‌های پستان ترجیح داده شده است.

بر خلاف مطالعات [۳، ۱۴، ۲۲] که محدود به کلاس‌های خوش‌خیم و بدخیم بوده‌اند، رویکرد این مقاله با تهیه‌ی مجموعه‌ی داده‌ای در سه کلاس که از ۱۷۰ ضایعه‌ی پستان ثبت شده، ارزیابی شده است. پیچیدگی‌های روش‌های کانتور [۱۰، ۲۳] برای استخراج ناحیه‌ی ضایعه در این روش مشاهده نشده است. مرحله‌ی انتخاب ویژگی‌های بهینه می‌تواند در باره‌ی تاثیر حوزه‌هایی که از آن‌ها ویژگی‌های مورد نظر استخراج شده است اطلاعات مناسبی را فراهم آورد. در ادامه طبقه‌بندی‌های مختلفی در حوزه‌ی یادگیری ماشین، به تنهایی و در کنار روش طبقه‌بندی همراه با مرجع^۲ (RCM) بررسی شده است. روش RCM بر اساس اختلاف بین ویژگی‌های مرجع و دیگر ویژگی‌ها است. بهره‌گیری از این روش در طبقه‌بندی بهینه، به دلیل ایجاد فضایی بر اساس اختلاف ویژگی‌ها، تاثیر به‌سزایی دارد.

در ادامه‌ی این مقاله در بخش ۲ به معرفی روش‌های مورد استفاده برای انتخاب ناحیه‌ی مورد نظر^۳ (ROI)، استخراج ویژگی‌ها، انتخاب ویژگی‌های بهینه و طبقه‌بندی ضایعات پرداخته شده است. هم‌چنین در بخش ۳ نتایج حاصل از طبقه‌بندی ضایعات پستان به دو و سه کلاس بر اساس روش پیشنهادی ارائه شده و مقایسه‌ی این پژوهش با سایر تحقیقات

۲-۱- ثبت دادگان

دنباله‌ای از پژواک‌های RF دریافت شده از یک مکان در بافت، یک سری زمانی RF را تشکیل می‌دهد [۲۶]. در این پژوهش

^۳ Region of Interest (ROI)

^۴ Suspicious

^۱ Black Box

^۲ Reference Classification Method (RCM)

به دست آید. شمایی از نحوه‌ی ثبت داده و قرارگیری بیمار روی تخت در شکل (۳) نشان داده شده است.

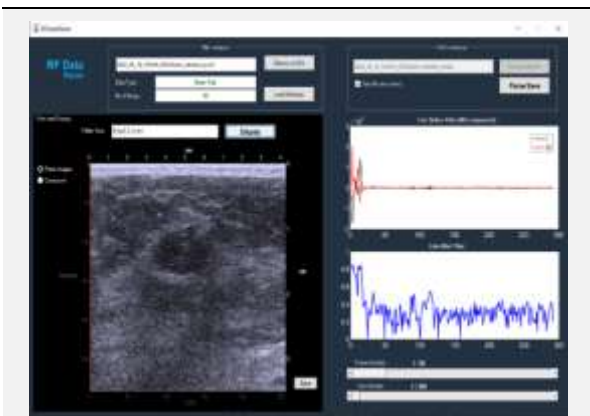


شکل (۳) - نحوه‌ی ثبت داده و قرارگیری بیمار روی تخت

۲-۲- پیش پردازش


۲-۲-۱- تبدیل سیگنال RF به تصویر B-mode

با توجه به این که سیگنال RF ثبت شده توسط دستگاه در قالب خاصی ذخیره می‌شود، به منظور خوانش این سیگنال در نرم‌افزار MATLAB باید فایل‌های ثبت شده به قالب MAT تبدیل شوند. در همین راستا از یک رابط کاربری گرافیکی^۴ (GUI) به نام خوانش داده‌ی RF^۵ برای تبدیل هر سیگنال RF ثبت شده به یک فایل MAT استفاده شده است. این GUI یک تصویر B-mode از هر سیگنال RF ثبت شده نیز می‌سازد و سیگنال RF و تصویر B-mode متناظر با آن را نمایش می‌دهد. شمای کلی GUI خوانش داده، بخشی از سیگنال RF ثبت شده از یک ضایعه‌ی خوش خیم و تصویر B-mode ضایعه در شکل (۴) نشان داده شده است.



شکل (۴) - شمای کلی GUI خوانش داده به همراه تصویر B-mode بازسازی شده از سیگنال RF ثبت شده از یک ضایعه‌ی خوش خیم

از سری زمانی فرکانس رادیویی اولتراسوند^۱ (USRFTS) که مجموعه‌ای از قاب‌های سیگنال‌های RF و تصاویر B-mode متناظر آن‌ها بوده استفاده شده است. این مجموعه‌ی داده در مرکز تصویربرداری دزاشیب (تهران، ایران) با یک سیستم پزشکی/تحقیقاتی^۲ ساخت فرانسه ثبت شده است. این سیستم مجهز به کاوش گر خطی SuperLinear™ SL18-5 است که با فرکانس مرکزی ۵-۱۸ مگاهرتز کار می‌کند. این مجموعه‌ی داده از فروردین تا تیر ۱۴۰۱ ثبت شده است. تعداد ضایعات بر اساس معیار BI-RADS در دسته‌های خوش خیم، مشکوک و بدخیم در شکل (۲) نشان داده شده است.



شکل (۲) - تعداد ضایعات در هر گروه بر اساس معیار BI-RADS

برای این تحقیق تاییدیه‌ی اخلاقی توسط کمیته‌ی اخلاقی دانشگاه آزاد اسلامی واحد علوم و تحقیقات صادر شده و رضایت آگاهانه از تمام شرکت کنندگان اخذ شده است. نمونه‌برداری و ماموگرافی برای تایید انواع ضایعات بدخیم و برخی ضایعات مشکوک انجام شده است. بر اساس نتایج آزمایش‌ها، پرتوشناس^۳ تصمیم گرفته که ضایعات احتمالاً خوش خیم و مشکوک را به مدت ۶ تا ۱۲ ماه تحت نظر داشته باشد [۲۷-۲۹]. در مجموع در این پژوهش ۱۷۰ ضایعه که از ۸۸ فرد به دست آمده بررسی و طبقه‌بندی شده است.

پیش از انجام هر ثبت، از بیمار خواسته شده است تا روی تخت دراز بکشد و دست‌های خود را بالای سر در راستای مبدل US قرار دهد تا بررسی ضایعات پستان برای پرتوشناس تسهیل شود. هنگام ثبت دادگان، مبدل و بافت بی حرکت باقی مانده است. در ادامه از بیمار خواسته شده است تا برای بررسی نواحی زیربغل به طرفین بچرخد. هم‌چنین در هنگام ثبت داده، از بیمار خواسته شده است که نفس خود را حبس کند تا ثبت با کیفیتی

^۴ Graphical User Interface (GUI)

^۵ RF Data Parser

^۱ USRF Time Series (USRFTS)

^۲ SuperSonic Imagine Aixplorer

^۳ Radiologist

حوزه‌ی زمان و فرکانس است. با اعمال تبدیل FFT به یک سیگنال در حوزه‌ی زمان، تمام اطلاعات زمانی سیگنال به اطلاعات فرکانسی تبدیل می‌شود [۳۰]. پس از تجزیه و تحلیل FFT از ROI، ۲۱ فرکانس انتخاب شده که به ترتیب شامل ۱۰ و ۱۱ مولفه از فرکانس‌های بالا/پایین بوده که پس از مرتب‌سازی فرکانس‌های FFT انتخاب شده است. در این مقاله از این پس این ۲۱ مولفه‌ی فرکانسی با عنوان فرکانس‌های منتخب نامیده شده است. بر اساس تحقیقات انجام شده، فرکانس‌های منتخب نقش مهمی در تمایز دقیق بین انواع مختلف ضایعات پستان ایفا کرده و از بازه‌های فرکانسی دیگر موثرتر هستند.

۲-۳-۲- ویژگی‌های زمانی

با توجه به مقاله‌ی [۳] میانگین، انحراف استاندارد^۲ (SD)، چولگی و کشیدگی از ROI تصویر B-mode استخراج شده است. علاوه بر موارد فوق، مشتق مرتبه‌ی اول و واریانس حاصل از تصاویر B-mode نیز در این پژوهش لحاظ شده است. واریانس و مشتق مرتبه‌ی اول جزو ویژگی‌های بافت در تصاویر B-mode در نظر گرفته می‌شوند [۳۱، ۳۲]. ویژگی‌های بافتی معیارهای آماری هستند که به آرایش فضایی شدت پیکسل‌ها در یک تصویر کمیت می‌دهند. واریانس به عنوان ویژگی آماری مرتبه‌ی اول^۳، به طور خاص درجه‌ی تغییر یا پراکندگی شدت پیکسل‌ها را در ROI یک تصویر توصیف می‌کند [۳۳، ۳۴]. واریانس می‌تواند بینشی در مورد همگنی یا ناهمگنی بافت ارائه دهد. مناطق با واریانس کم، شدت پیکسل‌های یک‌نواخت‌تر را نشان داده در حالی که مقادیر واریانس بالاتر، تنوع بیش‌تر در شدت پیکسل‌ها را نشان می‌دهند و همین مساله می‌تواند در تمایز بافت‌های مختلف کمک کند [۳۳]. مشتق مرتبه‌ی اول نشان دهنده‌ی نرخ تغییر شدت نور در تصویر به ازای تغییرات در مختصات فضایی است. در تصاویر B-mode سونوگرافی، این مشتق‌ها معمولاً به استخراج خصوصیات بافتی کمک می‌کنند. در مقالات [۳۵-۳۷] اشاره شده است که تغییر شدت نور می‌تواند در تمایز بین بافت خوش‌خیم و بدخیم اثرگذار باشد.

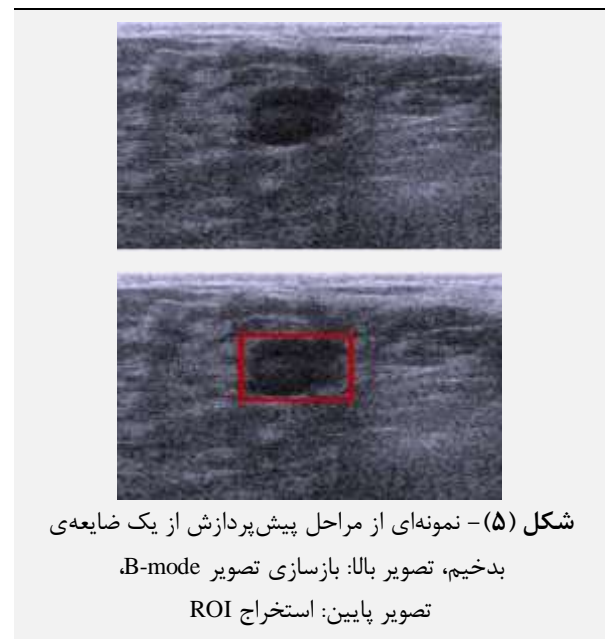
۲-۳-۳- ویژگی‌های زمان-فرکانس

۲-۳-۳-۱- بعد فراکتال

بعد فراکتال یک مفهوم ریاضی است که از آن برای تعیین کمیت پیچیدگی، ناهم‌واری یا خودشباهتی^۴ اشیا یا سیگنال‌هایی که الگوهای پیچیده، نامنظم و تکرارشونده را در

۲-۲- استخراج ناحیه‌ی مورد نظر (ROI)

در گام بعد پس از دستیابی به تصویر B-mode باید ROI استخراج شود. این ناحیه به صورت دستی توسط یک متخصص پرتوشناس انتخاب شده به طوری که پس از تعیین ضایعه توسط پرتوشناس، ROI حاوی ضایعه با استفاده از یک قاب مستطیلی استخراج شده است. انتخاب ROI با یک قاب مستطیلی باعث می‌شود که تجزیه و تحلیل به یک منطقه‌ی خاص محدود شود که در مقایسه با تحلیل کل تصویر می‌تواند بسیار مفید باشد. این مساله به تمرکز بر جزئیات ضروری در منطقه‌ی انتخابی کمک کرده و پردازش هدمندتر و کارآمدتری را تسهیل می‌کند. استفاده از این روش در مقایسه با روش کانتور، سریع‌تر، دارای حجم محاسباتی کم‌تر و به طور کلی با چالش کم‌تری همراه است [۳]. تصویر B-mode از یک سیگنال RF خام ثبت شده و ROI استخراج شده در شکل (۵) نشان داده شده است.



شکل (۵) - نمونه‌ای از مراحل پیش‌پردازش از یک ضایعه‌ی بدخیم، تصویر بالا: بازسازی تصویر B-mode، تصویر پایین: استخراج ROI

۲-۳-۲- استخراج ویژگی

ویژگی‌ها از تک قاب سیگنال RF و تصویر B-mode ساخته شده از دادگان RF در حوزه‌های فرکانس، زمان و زمان-فرکانس استخراج شده که این سه رویکرد اصلی استخراج ویژگی پیشنهادی در ادامه معرفی شده است.

۲-۳-۱- ویژگی‌های فرکانسی

برای برآورد طیف فرکانسی از تبدیل فوریه‌ی سریع^۱ (FFT) استفاده شده است. تبدیل FFT یک مبادله بین اطلاعات در دو

^۲ First-Order Statistical Feature

^۴ Self-Similarity

^۱ Fast Fourier Transform (FFT)

^۲ Standard Deviation (SD)

رشته‌ای از ویژگی‌ها بر مبنای فرکانس‌های منتخب با استفاده از عملگر مثلثاتی (برای مثال سینوس فرکانس ۱، سینوس فرکانس ۲، ... و سینوس فرکانس ۲۱) استخراج شده است. در نهایت ۲۹۱ ویژگی برای هر ROI به کار گرفته شده است تا در مرحله‌ی انتخاب ویژگی بررسی شود.

۲-۴- انتخاب ویژگی: کلونی مورچه

انتخاب ویژگی با استفاده از روش کلونی مورچه، یک روش بهینه‌سازی مبتنی بر رفتار واقعی کلونی مورچه‌ها و نحوه‌ی عمل کردن آن‌ها است که در جست‌وجوی منابع غذایی خود از فرایندهای تعاملی استفاده می‌کنند. در این روش، مفهومی از تعامل مورچه‌ها برای کشف و انتخاب ویژگی‌های مهم و تاثیرگذار در داده‌ها به کار می‌رود [۴۴]. بر همین اساس در زمینه‌ی انتخاب ویژگی، مورچه‌ها به طور مشابه از تعامل با ویژگی‌ها و ترکیب‌های مختلف آن‌ها برای یافتن مجموعه‌ای از ویژگی‌ها که منجر به بهبود عمل‌کرد مساله می‌شود استفاده می‌کنند [۴۵، ۴۶]. روش کلونی مورچه تصمیم انتقال^۵ خود را بر اساس قواعد احتمالاتی می‌گیرد که از اطلاعات اکتشافی محلی^۶ و تاریخچه‌ی راه‌های قبلی خود شکل گرفته است. گره‌های گراف با v_i نشان داده می‌شود که $1 \leq i \leq n$ و تعداد گره‌های گراف است. در مرحله‌ی اول، یک مورچه به صورت تصادفی یک گره را انتخاب کرده و آن گره را به عنوان یک گره بازدید شده علامت‌گذاری می‌کند. در مرحله‌ی بعد، مورچه گره دیگری را از بین $n-1$ گره باقی‌مانده با توجه به تابع انتقال به صورت رابطه‌ی (۱) انتخاب می‌کند [۴۶، ۴۷].

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha \eta_{ij}^\beta}{\sum_{l \in J_i^k} [\tau_{il}(t)]^\alpha \eta_{il}^\beta} & \text{if } j \in J_i^k \\ 0 & \text{Otherwise} \end{cases} \quad (1)$$

در این رابطه $P_{ij}^k(t)$ نشان دهنده‌ی احتمال انتقال از ویژگی i به ویژگی j برای مورچه‌ی k در زمان t است. هم‌چنین τ_{ij} مقدار دنباله‌ی فرومون^۷ در لبه‌ی بین ویژگی i و j در زمان t ، η_{ij} مطلوبیت اکتشافی لبه^۸ (i, j) و α و β دو پارامتری هستند که تعادل بین فرومون و اطلاعات اکتشافی را کنترل می‌کنند. به علاوه J_i^k مجموعه‌ای از گره‌های همسایه‌ی گره i بوده که هنوز توسط مورچه‌ی k بازدید نشده است [۴۶، ۴۷]. فرایند کلی انتخاب ویژگی کلونی مورچه در شکل (۶) قابل مشاهده است.

مقیاس‌های مختلف نشان می‌دهند استفاده می‌شود. از تجزیه و تحلیل ابعاد فراکتال به طور گسترده در علوم مختلف از جمله ریاضیات، فیزیک و زیست‌شناسی و در زمینه‌های پردازش تصویر و تجزیه و تحلیل داده‌ها استفاده می‌شود [۳۸]. استخراج ویژگی یکی از حوزه‌هایی است که در آن می‌توان از بعد فراکتال استفاده کرد. بعد فراکتال نشان دهنده‌ی بی‌نظمی یا پیچیدگی داده‌های US RF است. یکی از ویژگی‌های کارآمد به منظور توصیف بافت، بعد فراکتال بوده که در این پژوهش از هر تصویر B-mode استخراج شده است [۳۹].

الگوریتم‌های مختلفی برای محاسبه‌ی بعد فراکتال وجود دارد. در حوزه‌ی تشخیص سرطان سینه با استفاده از دادگان US RF می‌توان از بعد فراکتالی هیگوجی^۱ و کتز^۲ برای تجزیه و تحلیل بافت یا الگوهای درون بافت پستان استفاده کرد [۴۰-۴۲]. ضایعات سینه از جمله تومورهای سرطانی اغلب الگوهای نامنظم یا فراکتال ماندی را نشان می‌دهند که با بافت سالم پستان متفاوت است. با محاسبه‌ی بعد فراکتال هیگوجی و کتز می‌توان میزان پیچیدگی یا بی‌نظمی داده‌های US RF را اندازه‌گیری کرد و از این اطلاعات به عنوان ویژگی برای طبقه‌بندی یا تشخیص استفاده نمود. در این پژوهش از هر دو الگوریتم هیگوجی و کتز استفاده شده است.

۲-۳-۳- تبدیل موجک گسسته

تبدیل موجک گسسته^۳ (DWT) تبدیلی است که یک سیگنال را به تعدادی مجموعه تجزیه کرده و هر مجموعه یک سری زمانی از ضرایب بوده که تکامل زمانی سیگنال را در بازه‌ی فرکانسی مربوطه توصیف می‌کند [۴۳]. در این پژوهش از این الگوریتم به عنوان یک مبدل در فضای ثانویه استفاده شده و رشته‌ی عددی فرکانس‌های منتخب به عنوان ورودی به این الگوریتم با بهره‌گیری از عملگر دابیشز^۴ اعمال شده است.

۲-۳-۳-۲- ویژگی‌های مثلثاتی

علاوه بر ویژگی‌های ذکر شده، برخی از ویژگی‌های جدید از جمله سینوس، کسینوس، تانژانت و سایر توابع مثلثاتی فرکانس‌های منتخب نیز محاسبه شده به طوری که برای مثال ۲۱ فرکانس منتخب به عنوان رشته‌ای از اعداد به هر عملگر مثلثاتی (سینوس، کسینوس، تانژانت و ...) داده شده است. به عبارت دیگر به منظور بهره‌گیری از ویژگی‌های مثلثاتی،

^۵ Transition Decision

^۶ Local Heuristic Information

^۷ Pheromone

^۸ Heuristic Desirability of Edge

^۱ Higuchi's Fractal Dimension

^۲ Katz's Fractal Dimension

^۳ Discrete Wavelet Transform (DWT)

^۴ Daubechies 4

در این رابطه مقدار $0 < \rho < 1$ ثابت فروپاشی^۲ بوده که برای شبیه‌سازی تبخیر^۳ فرمون از آن استفاده شده و S^k زیرمجموعه‌ی ویژگی است که توسط مورچه‌ی k یافته می‌شود. فرمون با توجه به معیار خوبی^۴ زیرمجموعه‌ی ویژگی مورچه (γ') و اندازه‌ی خود زیرمجموعه به‌روز می‌شود. با این تعریف تمام مورچه‌ها می‌توانند فرمون را به‌روز کنند. مراحل اصلی الگوریتم کلونی مورچه به شرح زیر است [۴۷].

۱- تولید مورچه‌ها و مقداردهی اولیه‌ی فرمون

- جمعیت مورچه‌ها را تعیین کنید.
- شدت آزمایش فرمون مرتبط با هر ویژگی را تنظیم کنید.
- حداکثر تکرار مجاز را تعیین کنید.

۲- علوفه‌یابی و ارزیابی مورچه‌ها

• هر مورچه به‌طور تصادفی به یک ویژگی اختصاص داده شده و باید از تمام ویژگی‌ها بازدید کرده و راه حل‌ها را به‌طور کامل بسازد. در این مرحله معیار ارزیابی خطای طبقه‌بند است. اگر مورچه‌ای نتواند خطای طبقه‌بند را در دو مرحله‌ی متوالی کاهش دهد، کار خود را تمام کرده و خارج می‌شود.

۳- انتخاب بهترین مورچه‌ها

• در این مرحله اهمیت زیرمجموعه‌ی انتخابی هر مورچه از طریق عمل کرد طبقه‌بند ارزیابی شده و سپس زیرمجموعه‌ها بر اساس خطا انتخاب می‌شوند.

۴- بررسی معیار توقف

• اگر تعداد تکرارها از حداکثر تکرار مجاز بیش‌تر باشد، خارج شوید و در غیر این صورت ادامه دهید.

۵- به‌روزرسانی فرمون

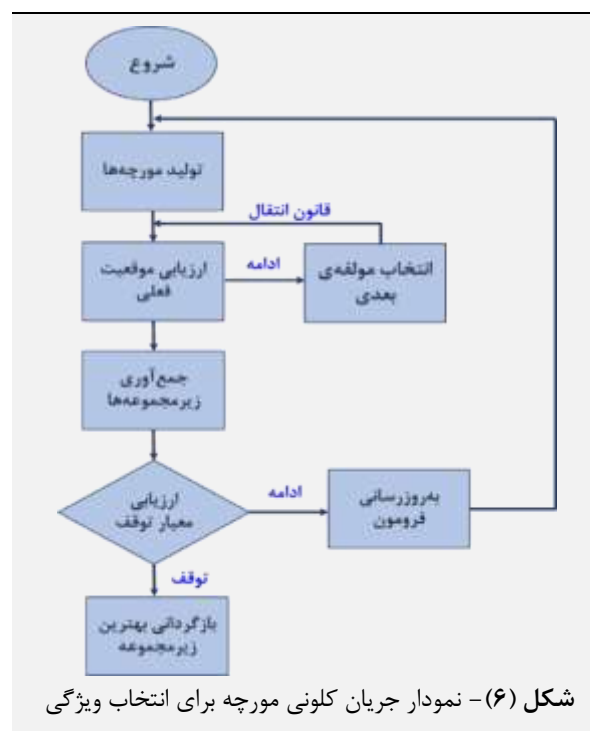
• برای ویژگی‌هایی که در مرحله‌ی ۳ انتخاب شده‌اند، شدت فرمون به‌روز می‌شود.

۶- نسل مورچه‌های جدید

• در این مرحله مورچه‌های قبلی حذف شده و مورچه‌های جدید تولید می‌شوند.

۷- به ۲ بروید و ادامه دهید.

در این پژوهش با بهره‌گیری از الگوریتم کلونی مورچه، ۳۸ ویژگی موثر انتخاب شده است. معیار توقف پیمایش برابر با ۱۰۰ تکرار بوده است. مقدار برازندگی با ۱۰۰ تکرار در شکل (۷) نشان داده شده که مطابق آن در تکرار ۴۰، جواب بهینه‌ی سراسری به دست آمده است.



شکل (۶) - نمودار جریان کلونی مورچه برای انتخاب ویژگی

این فرایند با تولید تعدادی مورچه شروع شده که در ادامه به‌طور تصادفی در گراف قرار می‌گیرند یعنی هر مورچه با یک ویژگی تصادفی شروع می‌شود. از طرف دیگر تعداد مورچه‌هایی که روی گراف^۱ قرار می‌گیرند ممکن است برابر با تعداد ویژگی‌های موجود در داده‌ها تنظیم شود. هر مورچه ساخت مسیر را با ویژگی متفاوتی شروع می‌کند. در ادامه مورچه‌ها از این موقعیت‌های اولیه، گره‌ها را به‌طور احتمالی طی می‌کنند تا زمانی که معیار توقف پیمایش برآورده شود. زیرمجموعه‌های به دست آمده جمع‌آوری شده و در ادامه ارزیابی می‌شوند. اگر یک زیرمجموعه‌ی بهینه پیدا شده باشد یا الگوریتم به تعداد معینی اجرا شده باشد، فرایند متوقف شده و بهترین زیرمجموعه‌ی ویژگی که با آن مواجه شده را به عنوان خروجی می‌دهد. اگر هیچ یک از این دو شرط برقرار نباشد، فرمون به‌روز شده، مجموعه‌ی جدیدی از مورچه‌ها ایجاد گشته و فرایند یک بار دیگر تکرار می‌شود. فرمون هر لبه طبق رابطه‌ی (۲) به‌روز می‌شود [۴۴، ۴۵، ۴۷، ۴۸].

$$\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \sum_{k=1}^m \Delta_{ij}^k(t) \quad (2)$$

در این رابطه، رابطه‌ی زیر برقرار است.

$$\Delta_{ij}^k(t) = \begin{cases} \gamma'(S^k)/|S^k| & \text{if } (i, j) \in S^k \\ 0 & \text{Otherwise} \end{cases} \quad (3)$$

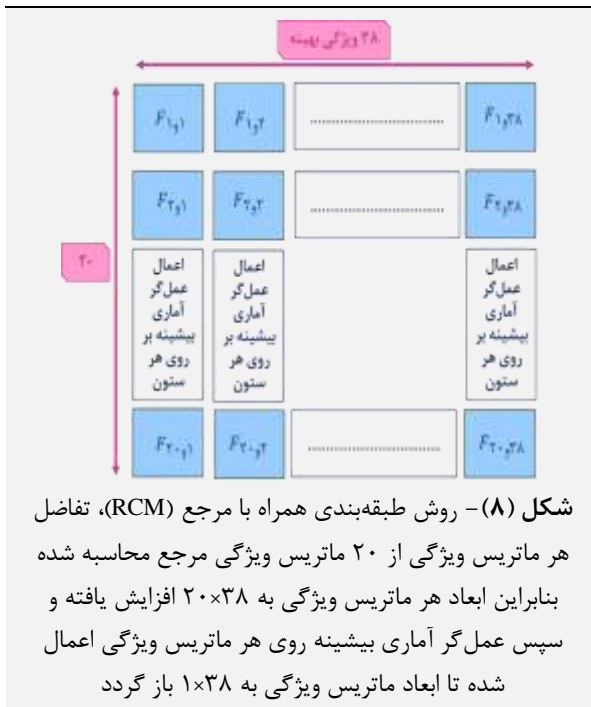
^۲ Evaporation

^۳ Goodness

^۱ Graph

^۲ Decay Constant

می‌رود که با استفاده از RCM نتایج دقیق‌تری حاصل شود. روند کلی روش RCM در شکل (۸) نشان داده شده است.



شکل (۷) - هم‌گرایی به جواب بهینه‌ی سراسری در تکرار ۴۰

۲-۵- طبقه‌بندی

برای طبقه‌بندی از طبقه‌بندهای SVM (کرنل خطی^۱)، KNN (فاصله‌ی اقلیدسی^۲)، DT و LDA همراه با اعتبارسنجی متقاطع^۳ پنج دسته‌ای استفاده شده است. دلیل انتخاب طبقه‌بند SVM زمان آموزش بسیار مناسب و کارآمد آن به ویژه در روش‌های تشخیص به کمک رایانه و کارایی بالای آن در مدیریت مجموعه‌ی داده‌های بزرگ و پیچیده است [۴۹].

طبقه‌بند KNN به عنوان یک روش یادگیری با نظارت برای تشخیص الگو عمل کرد خوبی دارد. این روش بر اساس ذخیره‌ی تمام نمونه‌ها و طبقه‌بندی موارد جدید از طریق ارزیابی شباهت و جست‌وجو در فضای الگو برای یافتن نزدیک‌ترین نمونه‌های آموزشی به نمونه‌های طبقه‌بندی نشده عمل می‌کند. طبقه‌بند DT یک مدل تصمیم‌گیری مبتنی بر قانون است که از نمودار درخت‌مانند استفاده می‌کند. از LDA در کاربردهای تشخیص الگو برای یافتن ترکیبی خطی برای مشخص یا جدا کردن دو یا چند کلاس از اشیاء استفاده می‌شود [۳، ۹، ۵۰، ۵۱].

در RCM به جای استفاده از خود ویژگی‌ها از اختلاف ویژگی‌ها برای طبقه‌بندی استفاده می‌شود به طوری که بخشی از دادگان یکی از کلاس‌ها به عنوان مرجع در نظر گرفته شده و در ادامه اختلاف دادگان باقی‌مانده با دادگان مرجع محاسبه می‌گردد. در نهایت برای این که ابعاد ماتریس ویژگی به ابعاد اولیه‌ی خود باز گردد از روش‌های آماری مانند میانگین، بیشینه و ... استفاده می‌شود. در این پژوهش ۲۰ نمونه از کلاس خوش‌خیم به عنوان مرجع انتخاب شده و در ادامه اقدامات ذکر شده انجام شده است. باید اشاره کرد که دادگان مرجع در طبقه‌بندی نهایی در نظر گرفته نشده است. در نهایت نتایج برای حالات مختلف با استفاده از روش بیشینه به دست آمده است. از آن‌جا که تفاوت بین ویژگی‌ها در طبقه‌بندی موثرتر از خود ویژگی‌ها است انتظار

۳- یافته‌ها و بحث

در فرایند طبقه‌بندی، داده‌ها در دو دسته (خوش‌خیم و بدخیم) و سه دسته (خوش‌خیم، مشکوک، بدخیم) لحاظ شده است. عمل کرد رویکرد پیشنهادی از طریق دقت^۴ (Pre)، حساسیت^۵ (Sen)، اختصاصیت^۶ (Spe)، صحت^۷ (Acc) و امتیاز^۸ (F_Sc) ارزیابی شده است.

۳-۱- نتایج

۳-۱-۱- طبقه‌بندی دادگان دوکلاسه

در این حالت داده‌های خوش‌خیم و بدخیم به دو دسته طبقه‌بندی شده که نتایج ارزیابی طبقه‌بندی با SVM، KNN، DT و LDA برای دادگان دوکلاسه در جدول (۱) آمده است.

جدول (۱) - نتایج طبقه‌بندی دادگان خوش‌خیم و بدخیم

بر حسب %

F_Sc	Spe	Acc	Sen	Pre	
۹۲/۹۸	۹۲/۰۶	۹۳/۲۸	۹۴/۶۴	۹۱/۳۸	SVM
۹۱/۷۴	۹۵/۲۴	۹۲/۴۴	۸۹/۲۹	۹۴/۳۴	KNN
۹۱/۷۴	۹۵/۲۴	۹۲/۴۴	۸۹/۲۹	۹۴/۳۴	LDA
۸۹/۷۲	۹۵/۲۴	۹۰/۷۶	۸۵/۷۱	۹۴/۱۲	DT

^۵ Sensitivity

^۶ Specificity

^۷ Accuracy

^۸ F-Score

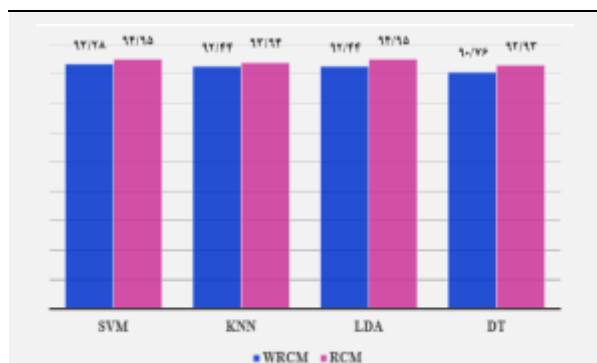
^۱ Linear

^۲ Euclidean Distance

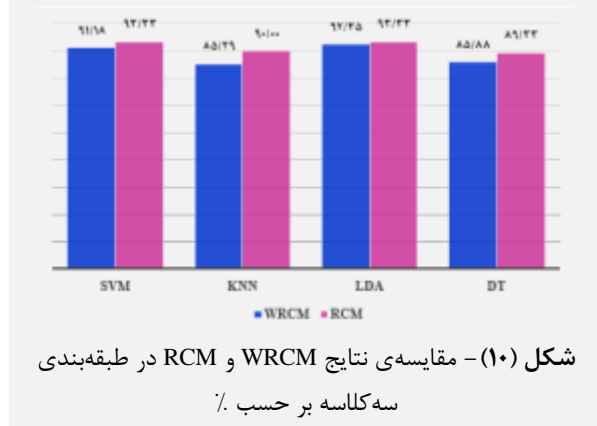
^۳ Cross Validation

^۴ Precision

چهارچوب یادگیری ماشین بررسی شده است. در ادامه با استفاده از روش کلونی مورچه، ویژگی‌های بهینه (۳۸ ویژگی) استخراج شده است. در شکل‌های (۹) و (۱۰) که از جداول (۱) تا (۴) استخراج شده‌اند، میزان صحت در دو روش طبقه‌بندی بدون مرجع^۱ (WRCM) و RCM به ترتیب برای طبقه‌بندی دو و سه کلاسه مقایسه شده است. بر اساس این شکل‌ها می‌توان بیان کرد که RCM باعث بهبود نتایج طبقه‌بندی با استفاده از هر چهار طبقه‌بند شده است.



شکل (۹) - مقایسه‌ی نتایج WRCM و RCM در طبقه‌بندی دو کلاسه بر حسب %



شکل (۱۰) - مقایسه‌ی نتایج WRCM و RCM در طبقه‌بندی سه کلاسه بر حسب %

در شکل‌های (۱۱) و (۱۲) که از جداول (۱) تا (۴) استخراج شده‌اند، نتایج طبقه‌بندی دو و سه کلاسه برای طبقه‌بندهای مختلف استفاده شده بدون/با RCM با هم مقایسه شده است. بر اساس این شکل‌ها می‌توان گفت که به طور کلی در طبقه‌بندی دو کلاسه در حالت WRCM، طبقه‌بند SVM و پس از آن طبقه‌بندهای LDA و KNN و با استفاده از RCM، طبقه‌بند SVM و پس از آن طبقه‌بند LDA بهترین نتایج را به طور میانگین داشته‌اند. در طبقه‌بندی سه کلاسه طبقه‌بند LDA و پس از آن طبقه‌بند SVM در حالت WRCM و طبقه‌بند SVM و پس از آن طبقه‌بند LDA در صورت استفاده از RCM نتایج مناسب‌تری را به طور میانگین به دست آورده‌اند.

۳-۱-۲- طبقه‌بندی دادگان سه کلاسه

در این‌جا دادگان خوش‌خیم، مشکوک و بدخیم به سه کلاس دسته‌بندی شده که نتایج ارزیابی طبقه‌بندی با SVM، KNN، DT و LDA برای دادگان سه کلاسه در جدول (۲) آمده است.

جدول (۲) - نتایج طبقه‌بندی دادگان خوش‌خیم، مشکوک و بدخیم بر حسب %

F_Sc	Spe	Acc	Sen	Pre	
۹۱/۴۰	۹۵/۴۰	۹۱/۱۸	۹۰/۹۳	۹۲/۳۸	SVM
۸۵/۷۰	۹۲/۴۵	۸۵/۲۹	۸۵/۳۱	۸۶/۳۸	KNN
۹۲/۵۸	۹۶/۰۸	۹۲/۳۵	۹۲/۵۹	۹۲/۶۲	LDA
۸۶/۰۹	۹۲/۹۰	۸۵/۸۸	۸۶/۶۰	۸۵/۹۸	DT

۳-۱-۳- طبقه‌بندی همراه با مرجع (RCM)

در این مرحله ۲۰ نمونه از کلاس خوش‌خیم به عنوان مرجع انتخاب شده و مجموعه‌ی داده با استفاده از طبقه‌بندهای SVM، KNN، DT و LDA به همراه اعتبارسنجی متقابل پنج دسته‌ی طبقه‌بندی شده است. نتایج طبقه‌بندی دو و سه کلاسه با روش RCM به ترتیب در جداول (۳) و (۴) ارائه شده است.

جدول (۳) - نتایج طبقه‌بندی دادگان خوش‌خیم و بدخیم با استفاده از روش RCM بر حسب %

F_Sc	Spe	Acc	Sen	Pre	
۹۲/۹۶	۹۶/۸۳	۹۴/۹۵	۹۱/۶۷	۹۴/۲۹	SVM
۹۱/۴۳	۹۶/۸۳	۹۳/۹۴	۸۸/۸۹	۹۴/۱۲	KNN
۹۳/۱۵	۹۵/۲۴	۹۴/۹۵	۹۴/۴۴	۹۱/۸۹	LDA
۹۰/۴۱	۹۳/۶۵	۹۲/۹۳	۹۱/۶۷	۸۹/۱۹	DT

جدول (۴) - نتایج طبقه‌بندی دادگان خوش‌خیم، مشکوک و بدخیم با استفاده از روش RCM بر حسب %

F_Sc	Spe	Acc	Sen	Pre	
۹۳/۳۸	۹۶/۲۶	۹۳/۳۳	۹۲/۵۰	۹۴/۷۶	SVM
۹۰/۱۷	۹۴/۴۸	۹۰/۰۰	۸۹/۳۶	۹۱/۷۸	KNN
۹۲/۶۰	۹۶/۶۷	۹۳/۳۳	۹۲/۶۰	۹۲/۶۰	LDA
۹۰/۱۶	۹۴/۳۳	۸۹/۳۳	۹۰/۱۲	۹۰/۲۸	DT

۳-۲- بحث

در این مقاله مجموعه‌ای از پارامترها برای طبقه‌بندی ضایعات خوش‌خیم، مشکوک و بدخیم پستان در دو و سه کلاس پیشنهاد شده است. در این روش پیشنهادی ۲۹۱ ویژگی استخراج شده از سری‌های زمانی US RF ثبت شده در

^۱ Without Reference Classification Method (WRCM)

از ساختارهایی مبتنی بر CNN به منظور طبقه‌بندی دو کلاسه‌ای ضایعات خوش‌خیم و بدخیم پستان با بهره‌گیری از دادگان OASBUD استفاده شده و در بهترین حالت تنها صحت ۷۰٪ به دست آمده است [۱۴]. در مقابل، روش پیشنهادی مقاله حاضر دقت طبقه‌بندی دو کلاسه را نسبت به روش جاروسیک به میزان ۲۳/۹۵٪ بهبود بخشیده است. محدودیت تعداد دادگان کم در ساختارهای مبتنی بر یادگیری عمیق در تحقیقات متعددی به چشم می‌خورد [۲۰، ۲۲، ۵۲]. به طور کلی مشاهده می‌شود که مدل‌های یادگیری عمیق معمولاً به داده‌های آموزشی قابل توجه، زمان آموزش زیاد و منابع محاسباتی پرهزینه نیاز دارند، در حالی که الگوریتم‌های مبتنی بر یادگیری ماشین به طور قابل توجهی به این پیش‌نیازها کم‌تر متکی بوده و در عین حال می‌توانند نتایج رضایت‌بخشی را ارائه دهند [۵۳، ۵۴]. روش‌های مختلف استخراج ویژگی و طبقه‌بندی مبتنی بر سری زمانی US RF ثبت شده از بافت پستان و نتایج حاصل از آن‌ها در جدول (۶) با هم مقایسه شده است.

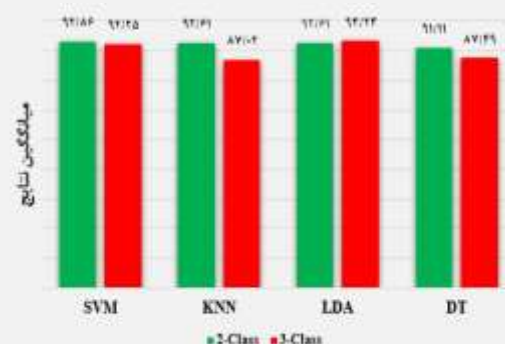
روش کلونی مورچه یک سیستم چندعاملی^۱ است که مزایایی مانند استفاده از حافظه‌ی بلندمدت توزیع شده^۲، بازخورد مثبت^۳، عمل‌کرد مشابه طرح‌واره‌ی یادگیری تقویتی^۴، قابلیت پیاده‌سازی موازی^۵ و قابلیت جست‌وجوی سراسری و محلی بر اساس مولفه‌های تصادفی و حریصانه^۶ را دارد [۵۵، ۵۶]. در یک مطالعه‌ی مرتبط از روش کلونی مورچه برای یافتن بهترین ویژگی‌های مربوط به تغییرات سرطانی برای ارتقای دقت طبقه‌بندی استفاده شده است [۵۷-۵۹].

جدول (۵) - ویژگی‌های موثر به دست آمده


مشق مرتبه‌ی اول
کشیدگی
تبدیل موجک گسسته (DWT)
ویژگی‌های مثلثاتی (سینوس، کسینوس و ...)



شکل (۱۳) - میزان مشارکت حوزه‌های مختلف استخراج ویژگی در ویژگی‌های بهینه



شکل (۱۱) - میانگین نتایج طبقه‌بندی دو کلاسه در حالت WRCM بر حسب %



شکل (۱۲) - میانگین نتایج طبقه‌بندی سه کلاسه در حالت RCM بر حسب %

برخی از ویژگی‌های موثر به دست آمده در این پژوهش در جدول (۵) ارائه شده است. میزان مشارکت حوزه‌های مختلف استخراج ویژگی در دست‌یابی به ویژگی‌های موثر را می‌توان در شکل (۱۳) مشاهده کرد. بر اساس این شکل ترکیب ویژگی‌های مثلثاتی بیش‌ترین مشارکت را داشته زیرا ۷۸٪ از ویژگی‌های بهینه مربوط به این دسته از ویژگی‌ها است. بر همین اساس می‌توان نتیجه گرفت که این دسته از ویژگی‌ها فضای داده را به فضای اطلاعاتی جدیدی منتقل کرده که تمایز بیشتری دارد و می‌تواند در دسته‌بندی ضایعات پستان موثرتر عمل کند.

در این بخش این پژوهش با سایر تحقیقات مبتنی بر دادگان US RF در زمینه‌ی ضایعات پستان مقایسه شده است. در مطالعات یونیا و هم‌کارانش فقط روی طبقه‌بندی دو کلاسه‌ی ضایعات پستان تمرکز شده است. تعداد بیماران در این پژوهش تنها ۲۲ نفر بوده که تنها ۷ نفر از آن‌ها دارای ضایعات بدخیم بوده‌اند [۳]. در پژوهش حاضر اما تعداد بیماران و دادگان در هر کلاس بسیار بیش‌تر بوده و هم‌چنین طبقه‌بندی سه کلاسه نیز در نظر گرفته شده است. در پژوهش جاروسیک و هم‌کارانش

^۱ Parallel Implementation Capability

^۲ Global as Well as Local Search Capability Based on Stochastic and Greedy Components

^۳ Multi-Agent System

^۴ Distributed Long-Term Memory

^۵ Positive Feedback

^۶ Similar Function to Reinforcement Learning Schema

جدول (۶) - مقایسه‌ی روش‌های استخراج ویژگی و طبقه‌بندی مبتنی بر سری زمانی RF ثبت شده از بافت پستان

پژوهش	دادگان	روش استخراج ویژگی	طبقه‌بند	کلاس‌ها	نتایج
[۳]	دادگان دانشگاه بریتیش کلمبیا ^۱ (۲۲ بیمار)	۱- محاسبه‌ی طیف فرکانسی از FFT بر اساس سری زمانی پنجره‌گذاری شده‌ی همینگ و متوسط‌گیری در چهار بازه‌ی فرکانسی، ۲- بعد فرکتال هیگوچی، ۳- استخراج شیب و گذر از مبدا رگرسیون به مقادیر طیف هنجار شده بر حسب فرکانس (۲۹ ویژگی)	SVM	۲	AUC: ۰.۸۶
[۱۴]	OASBUD (۷۸ بیمار و ۱۰۰ سیگنال RF)	یادگیری عمیق	CNN-1D CNN-2D CNN-1D-2D	۲	بهترین صحت: ۷۰٪
[۲۱]	۱۳۰ بیمار نمونه‌برداری شده (۱۰۴ خوش‌خیم و ۲۶ بدخیم)	ویژگی‌های مورفومتریک، عنصری و ترکیبی ^۲	SVM	۲	AUC: ۰.۹۳/۰.۸
[۵۲]	OASBUD (۷۸ بیمار و ۱۰۰ سیگنال RF)	تصاویر آنتروپی و فاز (به عنوان اطلاعات ریزساختاری و تشریحی ^۳)، تصاویر B-mode (به عنوان تصاویر پارامتری در حوزه‌ی زمان)، تصویر تضعیف ^۴ (به عنوان ویژگی‌های طیفی)	CNN گروهی ^۵	۲	صحت: ۸۳٪ با دنس‌نت-۲۰۱ ^۶ استفاده از
[۲۲]	OASBUD (۷۸ بیمار و ۱۰۰ سیگنال RF)	یادگیری عمیق	CNN منطقه‌ای سریع‌تر ^۷	۲	صحت بیش از ۹۵٪
روش پیشنهادی	USRFTS (۵۸ بیمار و ۱۱۹ سیگنال RF) و USRF (۸۸ بیمار و ۱۷۰ سیگنال RF)	ویژگی‌های حوزه‌ی زمان، فرکانس و زمان-فرکانس (۳۸ ویژگی بهینه)	SVM KNN LDA DT	۲ ۳	صحت: ۹۵/۹۴٪ صحت: ۹۳/۳۳٪

از مزایای اصلی این تحقیق می‌توان به تمرکز نه تنها بر طبقه‌بندی دوکلاسه بلکه بر طبقه‌بندی سه‌کلاسه، جمع‌آوری داده‌های سری زمانی US RF درون‌تنی از ضایعات مختلف پستان و استفاده از تعداد مناسب نمونه برای هر کلاس اشاره کرد. علاوه بر این بهره‌گیری از ویژگی‌های مختلف در حوزه‌های زمان، فرکانس و زمان-فرکانس در روش پیشنهادی، نوآورانه و منحصر به فرد بودن این پژوهش را افزایش داده است. هم‌چنین این پژوهش دید مناسبی از ویژگی‌های بهینه بر اساس الگوریتم کلونی مورچه ارائه داده است. با توجه به این که RCM می‌تواند نتایج طبقه‌بندی مبتنی بر سیگنال‌های US RF یا حتی تمام روش‌های طبقه‌بندی به کمک کامپیوتر را بهبود بخشد، یکی دیگر از ویژگی‌های این مطالعه، پیشنهاد استفاده از RCM است.

۴- نتیجه‌گیری

با هدف طبقه‌بندی ضایعات پستان به صورتی دقیق و غیرتهاجمی، در این مقاله روشی چندپارامتری بر اساس دادگان

به منظور اعتبارسنجی بیش‌تر روش پیشنهادی این مقاله، تکنیک اعتبارسنجی ده دسته‌ای نیز مورد استفاده قرار گرفته که بر اساس آن مقدار میانگین صحت در طبقه‌بندی دو و سه کلاسه به ترتیب برابر با ۰.۹۵/۰.۰۶ و ۰.۹۱/۰.۴۹ به دست آمده است. به نظر نمی‌رسد که بهبود جزئی حاصل از این روش ناشی از روش اعتبارسنجی ده دسته‌ای باشد زیرا با تکرار اعتبارسنجی می‌توان به این نتایج نیز دست یافت.

روش پیشنهادی را می‌توان به عنوان یک ابزار کاربردی برای طبقه‌بندی ضایعات پستان در نظر گرفت. نتایج ارائه شده، سری زمانی US RF را به عنوان یک راه حل مناسب با مزیت عدم نیاز به تجهیزات تکمیلی تایید می‌کند. این رویکرد مستقل از شکل کانتور و فرایند تقسیم‌بندی است. شایان ذکر است که عواملی مانند تجربه‌ی پرتوشناس، ثبت داده‌ها با یک دستگاه پیش‌رفته‌ی پزشکی/تحقیقاتی و به حداقل رساندن حرکت بیمار و تاثیر آن روی داده‌ها، همان‌طور که در این تحقیق لحاظ شده است می‌تواند داده‌های مناسبی را فراهم کند.

^۵ Ensemble

^۶ DenseNet-201

^۷ Faster Region Convolutional Neural Networks (Faster R-CNN)

^۱ British Columbia University Dataset

^۲ Morphometric, Elemental and Hybrid Features

^۳ Microstructural and Anatomical Information

^۴ Attenuation Image

- approximate displacement measurements," *J. Healthc. Eng.*, vol. 2019, pp. 1-12, Jan 2019.
- [5] T. M. Kolb, J. Lichy, and J. H. Newhouse, "Comparison of the performance of screening mammography, physical examination, and breast US and evaluation of factors that influence them: an analysis of 27,825 patient evaluations," *Radiology*, vol. 225, no. 1, pp. 165-75, Oct 2002.
- [6] W. A. Berg et al., "Combined screening with ultrasound and mammography vs mammography alone in women at elevated risk of breast cancer," *Jama*, vol. 299, no. 18, pp. 2151-63, May 2008.
- [7] G. Rahbar et al., "Benign versus malignant solid breast masses: US differentiation," *Radiology*, vol. 213, no. 3, pp. 889-94, Dec 1999.
- [8] Y. Zheng, J. F. Greenleaf, and J. J. Gisvold, "Reduction of breast biopsies with a modified self-organizing map," *IEEE Trans Neural Netw*, vol. 8, no. 6, pp. 1386-96, Nov 1997.
- [9] K. Donohue, L. Huang, T. Burks, F. Forsberg, and C. Piccoli, "Tissue classification with generalized spectrum parameters," *Ultrasound Med Biol*, vol. 27, no. 11, pp. 1505-14, Nov 2001.
- [10] S. Joo, Y. S. Yang, W. K. Moon, and H. C. Kim, "Computer-aided diagnosis of solid breast nodules: Use of an artificial neural network based on multiple sonographic features," *IEEE Trans Med Imaging*, vol. 23, no. 10, pp. 1292-300, Oct 2004.
- [11] M. Moradi, P. Abolmaesumi, D. R. Siemens, E. E. Sauerbrei, A. H. Boag, and P. Mousavi, "Augmenting detection of prostate cancer in transrectal ultrasound images using SVM and RF time series," *IEEE Trans Biomed Eng*, vol. 56, no. 9, pp. 2214-24, Sep 2009.
- [12] M. Mehdi, S. S. Mahdavi, N. Guy, C. J. Edward, S. L. Goldenberg, and E. S. Septimiu, "Ultrasound RF time series for tissue typing: First in vivo clinical results," in *Proc.SPIE, Brussels, Belgium*, pp. 86701I-8, Mar 2013.
- [13] M. Moradi, P. Abolmaesumi, and P. Mousavi, "Tissue typing using ultrasound RF time series: Experiments with animal tissue samples," *Med Phys*, vol. 37, no. 8, pp. 4401-13, Aug 2010.
- [14] P. Jarosik, Z. Klimonda, M. Lewandowski, and M. Byra, "Breast lesion classification based on ultrasonic radio-frequency signals using convolutional neural networks," *Biocybern Biomed Eng.*, vol. 40, pp. 977-986, May 2020.
- [15] Y. Yan et al., "Research on diagnosis of breast cancer based on ultrasonic radio frequency signals," *Nanosci Nanotechnol Lett*, vol. 11, no. 8, pp. 1116-1124, Aug 2019.
- [16] M. Qiao, Z. Fang, Y. Guo, S. Zhou, C. Chang, and Y. Wang, "Breast calcification detection based on multichannel radiofrequency signals via a unified deep learning framework," *Expert Syst. Appl.*, vol. 168, no. 114218, pp. 1-11, Apr 2021.

US RF پیشنهاد شده است. هم‌چنین مجموعه‌ی داده‌ی USRFTS که شامل سه کلاس از ضایعات پستان بر اساس امتیاز BI-RADS بوده ثبت شده است. استخراج ویژگی‌های مختلف از دادگان US RF زمانی همراه با استفاده از چهارچوب طبقه‌بندی یادگیری ماشین منجر به سرعت، حساسیت و اختصاصیت بالا شده است. می‌توان نتیجه گرفت که رویکرد پیشنهادی این مقاله یک روش عملی دقیق برای بهبود ارزیابی‌های BI-RADS است. هم‌چنین این روش می‌تواند یادآوری‌های مورد نیاز پس از ماموگرافی را کاهش دهد. بنابراین در این مقاله به یک نیاز بالینی اساسی پرداخته شده است. در ایجاد پایگاه داده‌ی مورد استفاده در این تحقیق به دلیل محدودیت امکانات موجود، امکان ثبت و جمع‌آوری دادگان از دستگاه‌های سونوگرافی/الاستوگرافی متفاوت و توسط ناظران مختلف وجود نداشته است. نویسندگان این مقاله قصد دارند در مطالعات آتی از پایگاه داده‌ای که با استفاده از سیستم‌های متفاوت و توسط چندین ناظر ثبت شده است استفاده کنند تا وابستگی نتایج به سیستم و شرایط تصویربرداری و تغییر کاربر را بررسی نمایند. هم‌چنین انتظار می‌رود که با افزایش داده‌ها و انجام مطالعات بیشتر در حوزه‌های مرتبط مانند پیش‌پردازش سیگنال‌های RF، بخش‌بندی تصاویر B-mode و طبقه‌بندی بتوان نتایج طبقه‌بندی را بهبود بخشید.

۵- سپاس‌گزاری

نویسندگان از مدیر شرکت تن‌آسا طب نوین، مهندس رضا رشیدزاده و کارمندان این شرکت برای کمک در جمع‌آوری داده‌ها تشکر و قدردانی می‌کنند.

۶- مراجع

- [1] P. Tahmasebi, M. M. Dastjerdi, A. Fallah, and S. Rashidi, "Estimation of linear and nonlinear elastic parameters of prostate tumors using artificial neural networks: Estimation of linear and nonlinear elastic parameters of tumors," in *27th National and 5th International Iranian Conference on Biomedical Engineering (ICBME)*, Tehran, Iran, pp. 87-96, Nov 2020.
- [2] G. C. Observatory. (2021). Population Fact Sheets of Iran 2020. Available: <https://gco.iarc.fr/today/data/factsheets/populations/364-iran-islamic-republic-of-fact-sheets.pdf>
- [3] N. Uniyal et al., "Ultrasound RF time series for classification of breast lesions," *IEEE Trans Med Imaging*, vol. 34, no. 2, pp. 652-61, Feb 2015.
- [4] M. M. Dastjerdi, A. Fallah, and S. Rashidi, "An iterative method for estimating nonlinear elastic constants of tumor in soft tissue from



- Roentgenol, vol. 206, no. 3, pp. 666-72, Mar 2016.
- [29] K. Fatima, I. Masroor, and S. Khanani, "Probably benign solid breast lesions on ultrasound: need for biopsy reassessed," *Asian Pac J Cancer Prev*, vol. 19, no. 12, pp. 3467-3471, Dec 2018.
- [30] S. Johnson and M. Frigo, "A modified split-radix FFT with fewer arithmetic operations," *IEEE Trans. Signal Process.*, vol. 55, no. 1, pp. 111-119, Dec 2007.
- [31] Y. Li, Y. Liu, M. Zhang, G. Zhang, Z. Wang, and J. Luo, "Radiomics with attribute bagging for breast tumor classification using multimodal ultrasound images," *J Ultrasound Med*, vol. 39, no. 2, pp. 361-371, Aug 2020.
- [32] M. B. Subramanya, V. Kumar, S. Mukherjee, and M. Saini, "SVM-based CAC system for B-mode kidney ultrasound images," *J Digit Imaging*, vol. 28, no. 4, pp. 448-58, Dec 2015.
- [33] S. Malkov et al., "Mammographic texture and risk of breast cancer by tumor type and estrogen receptor status," *Breast Cancer Res*, vol. 18, no. 1, pp. 1-11, Dec 2016.
- [34] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural features for image classification," *IEEE Trans. Syst. Man Cybern. Syst.*, vol. SMC-3, no. 6, pp. 610-621, Jan 1973.
- [35] H. Pezeshki, M. Rastgarpour, A. Sharifi, and S. Yazdani, "Extraction of spiculated parts of mammogram tumors to improve accuracy of classification," *Multimed. Tools Appl.*, vol. 78, no. 14, pp. 1-25, Feb 2019.
- [36] K. Loizidou, G. Skouroumouni, C. Nikolaou, and C. Pitris, "An automated breast micro-calcification detection and classification technique using temporal subtraction of mammograms," *IEEE Access*, vol. 8, pp. 1-11, Mar 2020.
- [37] D. A. Zebari et al., "Breast cancer detection using mammogram images with improved multi-fractal dimension approach and feature fusion," *Appl. Sci.*, vol. 11, no. 24, pp. 1-28, Dec 2021.
- [38] B. B. Mandelbrot, *Gaussian Self-Affinity and Fractals*. Harrisonburg: Springer, 2002.
- [39] C. K. Loo, A. Samraj, and G. C. Lee, "Evaluation of methods for estimating fractal dimension in motor imagery-based brain computer interface," *Discrete Dyn. Nat. Soc.*, vol. 2011, pp. 1-8, Jan 2011.
- [40] T. Higuchi, "Approach to an irregular time series on the basis of the fractal theory," *Phys. D: Nonlinear Phenom.*, vol. 31, no. 2, pp. 277-283, Jun 1988.
- [41] M. J. Katz, "Fractals and the analysis of waveforms," *Comput. Biol. Med.*, vol. 18, no. 3, pp. 145-156, Jan 1988.
- [42] A. Petrosian, "Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns," in *Proceedings 8th IEEE Symposium on Computer-Based Medical Systems*, Lubbock, TX, USA, pp. 212-217, Jun 1995.
- [17] H. Taleghamar, H. Moghadas-Dastjerdi, G. J. Czarnota, and A. Sadeghi-Naini, "Characterizing intra-tumor regions on quantitative ultrasound parametric images to predict breast cancer response to chemotherapy at pre-treatment," *Sci. Rep.*, vol. 11, no. 1, pp. 1-13, Jul 2021.
- [18] M. Byra et al., "Joint segmentation and classification of breast masses based on ultrasound radio-frequency data and convolutional neural networks," *Ultrasonics*, vol. 121, no. 6, Apr 2022.
- [19] G. R. Gare et al., "W-Net: Dense and diagnostic semantic segmentation of subcutaneous and breast tissue in ultrasound images by incorporating ultrasound RF waveform data," *Med. Image Anal.*, vol. 76, pp. 1-14, Feb 2022.
- [20] H. Taleghamar, S. A. Jalalifar, G. J. Czarnota, and A. Sadeghi-Naini, "Deep learning of quantitative ultrasound multi-parametric images at pre-treatment to predict breast cancer response to chemotherapy," *Sci. Rep.*, vol. 12, no. 1, pp. 1-13, Feb 2022.
- [21] A. Chowdhury et al., "Ultrasound classification of breast masses using a comprehensive Nakagami imaging and machine learning framework," *Ultrasonics*, vol. 124, no. 3, Aug 2022.
- [22] K. Wei, B. Wang, and J. Saniie, "Faster region convolutional neural networks applied to ultrasonic images for breast lesion detection and classification," in *2020 IEEE International Conference on Electro Information Technology (EIT)*, Chicago, IL, USA, pp. 171-174, Jul 2020.
- [23] W. Gómez Flores, W. C. d. A. Pereira, and A. F. C. Infantsi, "Improving classification performance of breast lesions on ultrasonography," *Pattern Recognit.*, vol. 48, no. 4, pp. 1125-1136, Apr 2015.
- [24] I. Warnich, I. Viljoen, and M. Kuehnast, "Breast imaging at Chris Hani Baragwanath Academic Hospital: A clinically relevant audit," *SA Journal of Radiology*, vol. 24, no. 1, pp. 1-11, Oct 2020.
- [25] G.-C. Hsu and J.-C. Yu, "American college of radiology breast imaging reporting and data system ultrasound: An overview of the second edition," *J. Med. Ultrasound*, vol. 23, no. 3, pp. 117-119, Aug 2015.
- [26] E. J. Feleppa et al., "Typing of prostate tissue by ultrasonic spectrum analysis," *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, vol. 43, no. 4, pp. 609-619, Jul 1996.
- [27] H. J. Moon, M. J. Kim, J. H. Yoon, and E. K. Kim, "Follow-up interval for probably benign breast lesions on screening ultrasound in women at average risk for breast cancer with dense breasts," (in eng), *Acta Radiol*, vol. 59, no. 9, pp. 1045-1050, Sep 2018.
- [28] E. Y. Chae, J. H. Cha, H. J. Shin, W. J. Choi, and H. H. Kim, "Reassessment and follow-up results of BI-RADS category 3 lesions detected on screening breast ultrasound," *AJR Am J*

- descriptors," *Comput Math Methods Med*, vol. 2022, pp. 1-18, Mar 2022.
- [52] S. Kim, J. Park, J. Yi, and H. Kim, "End-to-end convolutional neural network framework for breast ultrasound analysis using multiple parametric images generated from radiofrequency signals," *Appl. Sci.*, vol. 12, no. 10, pp. 1-17, May 2022.
- [53] P. M. Shankar et al., "Classification of ultrasonic B-mode images of breast masses using Nakagami distribution," *IEEE Trans Ultrason Ferroelectr Freq Control*, vol. 48, no. 2, pp. 569-80, Mar 2001.
- [54] Y. L. Huang and D. R. Chen, "Support vector machines in sonography: Application to decision making in the diagnosis of breast cancer," *Clin Imaging*, vol. 29, no. 3, pp. 179-84, May-Jun 2005.
- [55] B. Z. Dadaneh, H. Y. Markid, and A. Zakerolhosseini, "Unsupervised probabilistic feature selection using ant colony optimization," *Expert Syst. Appl.*, vol. 53, pp. 27-42, Jul 2016.
- [56] M. Dorigo and T. Stützle, *Ant colony optimization: overview and recent advances (Handbook of Metaheuristics)*. 2018.
- [57] O. Fallahzadeh, Z. Dehghani-Bidgoli, and M. Assarian, "Raman spectral feature selection using ant colony optimization for breast cancer diagnosis," *Lasers Med Sci.*, vol. 33, no. 8, pp. 1799-1806, June 2018.
- [58] S. Panigrahi, H. Swapnarekha, and S. Subudhi, "GACO: A genetic algorithm with ant colony optimization—based feature selection for breast cancer diagnosis," in *Nature-Inspired Optimization Methodologies in Biomedical and Healthcare Cham*: Springer International Publishing, pp. 269-293, Nov 2022.
- [59] P. Shunmugapriya and S. Kanmani, "A hybrid algorithm using ant and bee colony optimization for feature selection and classification (AC-ABC Hybrid)," *Swarm Evol. Comput.*, vol. 36, pp. 27-36, Oct 2017.
- [43] F. Imani et al., "Computer-aided prostate cancer detection using ultrasound RF time series: In vivo feasibility study," *IEEE Trans Med Imaging*, vol. 34, no. 11, pp. 2248-57, Nov 2015.
- [44] M. H. Aghdam, N. Ghasem-Aghaee, and M. E. Basiri, "Text feature selection using ant colony optimization," *Expert Syst. Appl.*, vol. 36, no. 3, Part 2, pp. 6843-6853, Apr 2009.
- [45] A. Jayaprakash and C. KeziSelvaVijila, "Feature selection using ant colony optimization (ACO) and road sign detection and recognition (RSDR) system," *Cogn. Syst. Res.*, vol. 58, pp. 123-133, Dec 2019.
- [46] B. Z. Dadaneh, H. Y. Markid, and A. Zakerolhosseini, "Unsupervised probabilistic feature selection using ant colony optimization," *Expert Syst. Appl.*, vol. 53, pp. 27-42, Jul 2016.
- [47] E. Basiri, N. Ghasem-Aghaee, and M. Hosseinzadeh Aghdam, "Using ant colony optimization-based selected features for predicting post-synaptic activity in proteins," in *Evolutionary Computation, Machine Learning and Data Mining in Bioinformatics, 6th European Conference (EvoBIO)*, Naples, Italy, Mar 2008, vol. 4973, pp. 12-23.
- [48] H. R. Kanan, K. Faez, and S. M. Taheri, "Feature selection using ant colony optimization (ACO): A new method and comparative study in the application of face recognition system," in *Industrial Conference on Data Mining, Leipzig, Germany*, pp. 63-76, Aug 2007.
- [49] R. F. Chang, W. J. Wu, W. K. Moon, Y. H. Chou, and D. R. Chen, "Support vector machines for diagnosis of breast tumors on US images," *Acad Radiol*, vol. 10, no. 2, pp. 189-97, Feb 2003.
- [50] E. Fleury and K. Marcomini, "Performance of machine learning software to classify breast lesions using BI-RADS radiomic features on ultrasound images," *Eur. Radiol. Exp.*, vol. 3, no. 1, pp. 1-8, Dec 2019.
- [51] S. Muhtadi, "Breast tumor classification using intratumoral quantitative ultrasound