

## **Deep Learning-Enhanced Breast Lesion Classification and Grading Using Novel RFTSDP Approach**

**Norouzi Ghehi, Elaheh<sup>1</sup> / Fallah, Ali<sup>2\*</sup> / Rashidi, Saeid<sup>3</sup> / Mehdizadeh Dastjerdi, Maryam<sup>4</sup>**

<sup>1</sup> - Ph.D. Candidate, Bioelectric, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

<sup>2</sup> - Associate Professor, Bioelectric, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

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

<sup>4</sup> - Biomedical Engineering Ph.D., Bioelectric, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

### **ARTICLE INFO**

DOI: 10.22041/ijbme.2025.2052844.1961

Received: 8/2/2025

Revised: 29/4/2025

Accepted: 9/5/2025

### **KEYWORDS**

*Breast Lesions  
Classification and  
Grading  
Deep Learning  
Dynamic Tissue  
Stimulation  
RFTSDP Method  
Ultrasound RF Time  
Series*

### **ABSTRACT**

Early detection of breast lesion types is crucial for timely intervention and improved clinical outcomes. However, current diagnostic methods often lack sufficient accuracy and frequently necessitate invasive biopsies for definitive diagnosis. To address this limitation, we proposed a novel approach known as Radio Frequency Time Series Dynamic Profiling (RFTSDP) in 2020. This method analyzes radio frequency (RF) backscatter signals during controlled stimulations, revealing tissue mechanical properties and providing richer information about the dynamic microenvironment. In this study, we developed and implemented a device capable of generating vibrations at varying frequencies. Data were acquired from 11 ex-vivo human breast tissue samples embedded in a healthy breast tissue-mimicking phantom. Ultrafast beamformed data were collected under three conditions: no stimulation, constant force, and vibrational stimulation at various frequencies, using a Supersonic Imagine ultrasound system. Deep learning techniques were employed for automated feature extraction, classification, and grading of the tissue samples into five categories. The performance of the deep learning-based RFTSDP method was compared with conventional machine learning approaches, which involved spectral and nonlinear feature extraction from RF time series, followed by classification using a Support Vector Machine (SVM). Incorporating 65 Hz vibration into the RFTSDP alongside deep learning achieved an accuracy of  $99.53\% \pm 0.47\%$  in classifying and grading breast lesions. Using deep learning for automated feature extraction and breast lesion classification led to increased performance accuracy and a more robust model. Furthermore, RFTSDP combined with deep learning demonstrated a 28.67% improvement in classification accuracy compared to the non-stimulation condition and the analysis of focused raw data. These results confirm that enriching backscatter signals using RFTSDP, particularly when integrated with deep learning, enhances the determination of breast lesion types and facilitates more accurate cancer grading.



## بهبود طبقه‌بندی و درجه‌بندی ضایعه‌های پستان با استفاده از یادگیری عمیق مبتنی بر روش جدید *RFTSDP*

الهه نوروزی قهی<sup>۱</sup> / فلاح، علی<sup>۲\*</sup> / رشیدی، سعید<sup>۳</sup> / مهدی‌زاده دستجردی، مریم<sup>۴</sup>

<sup>۱</sup> - دانشجوی دکتری، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

<sup>۲</sup> - دانشیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

<sup>۳</sup> - استادیار، گروه مهندسی پزشکی، دانشکده‌ی علوم و فناوری‌های پزشکی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

<sup>۴</sup> - دکتری مهندسی پزشکی، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

### مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2025.2052844.1961

پذیرش: ۱۴۰۴/۲/۱۹

بازنگری: ۱۴۰۴/۲/۹

ثبت در سامانه: ۱۴۰۳/۱۱/۲۰

### چکیده

### واژه‌های کلیدی

تشخیص به موقع نوع ضایعه‌ی پستان در انجام اقدامات لازم برای بهبود سریع‌تر بسیار مفید است. به دلیل دقت ناکافی روش‌های موجود، تعیین دقیق نوع ضایعه فقط با روش تهاجمی نمونه‌برداری میسر است. در روش جدید تحلیل دینامیکی سری زمانی فرکانس رادیویی فراصوت (*RFTSDP*) که در سال ۲۰۲۰ توسط ما پیشنهاد شد، سیگنال‌های بازگشتی RF در حین اعمال تحریک‌های مختلف بررسی می‌شوند. اعمال تحریک می‌تواند ویژگی‌های مکانیکی بافت را در سیگنال‌های بازگشتی آشکار کند و اطلاعات بیشتری از دینامیک محیط فراهم نماید. در این مطالعه، دستگاهی برای ایجاد لرزش در فرکانس‌های مختلف طراحی و استفاده شد. داده‌ها از ۱۱ نمونه بافت خارج‌شده از پستان که درون فانتوم شبیه‌ساز بافت سالم پستان قرار گرفته بودند، جمع‌آوری شدند. داده‌های بیم‌فرم‌شده‌ی فوق‌سریع تحت شرایط عدم تحریک، نیروی ثابت و تحریک لرزشی با فرکانس‌های مختلف با استفاده از سیستم تصویربرداری فراصوت سوپرسونیک جمع‌آوری شدند. از یادگیری عمیق برای استخراج خودکار ویژگی، طبقه‌بندی و درجه‌بندی ۱۱ نمونه بافت به پنج گروه مختلف ضایعه‌های سرطانی (سه گروه همراه درجه‌بندی)، غیرسرطانی (نکروز چربی) و بافت سالم استفاده شد. در نهایت، نتایج روش یادگیری عمیق با نتایج به‌دست آمده از استخراج ویژگی‌های طیفی و غیرخطی سری زمانی RF و طبقه‌بندی با ماشین بردار پشتیبان مقایسه شد. با اعمال لرزش ۶۵ هرتز در روش *RFTSDP* و استفاده از یادگیری عمیق، طبقه‌بندی انواع ضایعه‌های پستان و درجه‌بندی ضایعه‌ی سرطانی با صحت  $99/53 \pm 0/47$  درصد حاصل شد. استفاده از یادگیری عمیق به منظور استخراج خودکار ویژگی و طبقه‌بندی ضایعه‌ی پستان باعث افزایش صحت عملکرد و آرایه‌ی مدلی پایدارتر شد. همچنین بهبود قابل توجهی (۲۸/۶۷ درصد) در صحت طبقه‌بندی با استفاده از *RFTSDP* و بهره‌گیری از یادگیری عمیق نسبت به حالت بدون اعمال تحریک و ارزیابی داده‌های خام متمرکز حاصل شد. بنابراین نتایج این مطالعه تایید می‌کند که استفاده از روش *RFTSDP*، باعث غنی‌تر شدن سیگنال‌های بازگشتی و بهبود تعیین نوع ضایعه‌ی پستان و درجه‌بندی سرطان شده‌است.

تحریک دینامیکی بافت  
روش *RFTSDP*  
سری زمانی فرکانس رادیویی فراصوت ضایعه‌های پستان طبقه‌بندی و درجه‌بندی یادگیری عمیق

## ۱- مقدمه

ارتباط بین تغییرات خواص مکانیکی بافت و بیماری‌ها منجر به توسعه روش‌های ارتجاع‌نگاری<sup>۱</sup> شده‌است که بر خاصیت ارتجاعی بافت تمرکز دارند [۱، ۲]. در روش تصویربرداری ارتجاع‌نگاری، داده‌ی پایه که مورد استفاده قرار می‌گیرد، جابه‌جایی نسبی بافت می‌باشد. با اطلاعات حاصل از ضرایب ارتجاعی بافت، تشخیص دقیق‌تر صورت می‌گیرد [۳]. نتایج برخی مطالعات که در آن ضرایب ارتجاعی نمونه بافت طبیعی، ضایعه‌های غیرسرطانی و سرطانی پستان در خارج از بدن اندازه‌گیری شده‌اند، نشان می‌دهد که ضرایب ارتجاعی بافت‌های مختلف پستان به شدت وابسته به میزان نیرویی هستند که در هنگام اندازه‌گیری بر آنها اعمال می‌شود. این وابستگی، رفتار ارتجاعی غیرخطی در بافت‌های زیستی را تایید می‌کند. به این ترتیب در بسیاری از پژوهش‌ها به محاسبه‌ی ضریب ارتجاعی اکتفا نمی‌شود [۴].

در مطالعات اخیر، مدل‌های غیرخطی برای تقلید رفتار دینامیک و غیرخطی بافت در نظر گرفته می‌شوند که پارامترهای این مدل در روش‌های مختلف ارتجاع‌نگاری محاسبه می‌شوند. انجام این محاسبات بسیار پیچیده بوده و هر مدل می‌تواند تنها بخشی از خواص غیرخطی بافت را تقلید و پیاده‌سازی نماید [۵، ۶]. علاوه بر این، چالش‌های تشخیص مبتنی بر سونوگرافی شامل تضاد پایین در تصاویر، حالت روشنایی بالا و وابستگی به کاربر می‌باشند [۷].

در روش جدیدتری که به‌تازگی مورد توجه قرار گرفته، سیگنال‌های با فرکانس رادیویی<sup>۲</sup> (RF) ثبت‌شده از بافت بررسی می‌شوند. این روش مبتنی بر سونوگرافی توسط مرادی و همکاران در سال ۲۰۰۶ پیشنهاد شد که توالی‌ای از قاب‌های<sup>۳</sup> سیگنال RF را از یک مکان ثابت بافت ثبت و سری زمانی RF را ایجاد می‌کند. این روش بر تعاملات مستمر بین بافت و امواج سونوگرافی تکیه دارد زیرا سری زمانی بازسازی‌شده از امواج بازگشتی اطلاعات ارزشمندی درباره‌ی بافت حمل می‌کند [۸]. به طور خاص، استفاده از سری زمانی RF نیاز به مدل‌سازی بافت یا محاسبه‌ی پارامترهای مدل را از بین می‌برد [۹، ۱۰].

مرادی و همکاران تحقیقی گسترده با استفاده از سری زمانی RF روی فانتوم، بافت‌های حیوانی و بافت‌های پروستات به صورت برون‌تنی<sup>۴</sup> و درون‌تنی<sup>۵</sup> انجام دادند که کارایی این روش را در تعیین نوع بافت‌های حیوانی و طبقه‌بندی بافت پروستات

نشان داد [۱، ۵، ۸، ۱۰-۱۷]. همچنین نتایج بررسی‌های انجام‌شده در این راستا نشان داد که سیگنال‌های RF به‌دست‌آمده پیش از مدول داده‌ها بر اساس شدت روشنایی و تشکیل تصویر مد بی<sup>۶</sup>، می‌تواند اطلاعات بیشتری از بافت نسبت به روش سونوگرافی معمولی فراهم نماید [۱۲، ۱۴]. در این روش تجزیه و تحلیل، پارامترهای بافت بر خلاف روش مرسوم (تجزیه و تحلیل طیفی در بخش‌های فضایی سیگنال RF) از تغییرات زمانی سیگنال RF استخراج می‌شود [۱۸].

در روش‌های بر پایه‌ی سونوگرافی که برای تشخیص سرطان پروستات معرفی شده‌اند از جمله ارتجاع‌نگاری، آنالیز داده‌های RF به صورت مجزا در تعیین دقیق سرطان حتی در درجه‌ی بالا به طور کامل موفق نبوده‌اند. با این‌که پی‌بردن به وجود بسیاری از تومورهای بافت‌های بدن امکان‌پذیر است، تشخیص خوش‌خیم و بدخیم بودن آن‌ها بدون انجام نمونه‌برداری<sup>۷</sup> از بافت میسر نیست [۱۹]. این روش تهاجمی، هزینه‌ی مادی و روحی بسیار زیادی را به بیمار تحمیل می‌کند؛ علاوه بر این‌که چندین روز یا هفته طول می‌کشد تا نتیجه‌ی آزمایشی مشخص شود که نرخ‌های مثبت کاذب بالایی دارد؛ برای نمونه، نتایج ۸۰ درصد از نمونه‌برداری‌های انجام‌شده از پستان نشان می‌دهد ضایعه غیرسرطانی و خوش‌خیم است [۱۱]. به این ترتیب، استفاده از روشی کم‌هزینه، غیرتهاجمی، غیررادیواکتیو، قابل حمل و دقیق به عنوان ابزاری برای آگاهی از وجود و نوع ناهنجاری بافت پستان مورد نیاز می‌باشد.

به دلیل پیچیدگی بافت پستان در مقایسه با بافت پروستات، بررسی این نوع بافت و تصویربرداری آن نیاز به یک کاربر متخصص آموزش‌دیده دارد. همچنین پیشنهادشده که بافت پستان در محیط طبیعی خود مورد بررسی قرار گیرد که این امر به دلیل تأثیرات محیط و سایر بافت‌ها دشوار خواهد بود [۲۰]. با توجه به موارد ذکرشده و تعاملات بین بافت و سیگنال‌های فراصوت، لازم است اطلاعات بیشتری در مورد سیگنال‌های بازگشتی RF و روش دقیق‌تری برای استفاده از آن‌ها در طبقه‌بندی بافت پستان داشته باشیم.

در سال ۲۰۰۰ استفاده از ارتجاع‌نگاری پویا در گروه تحقیقاتی پروفیسور کوین پارکر در دانشگاه روچستر مورد بررسی جدی قرار گرفت. فواید استفاده از این روش در بسیاری از مقالات ذکرشده که در اینجا به صورت خلاصه اشاره شده‌است. برخلاف

<sup>۵</sup> In-vivo<sup>۶</sup> B-mode<sup>۷</sup> Biopsy<sup>۱</sup> Elastography<sup>۲</sup> Radio Frequency<sup>۳</sup> Frames<sup>۴</sup> Ex-vivo

داد که ثبت داده‌ها در حالت UF و در حین اعمال تحریک، ردیابی بهتر تاثیرات تحریک و لرزاننده بر الگوهای بازگشتی و جابجایی پراکنده‌کننده‌ها امکان‌پذیر می‌شود. در این پژوهش به بررسی کامل‌تر روش پیشنهادی با ثبت از داده‌های انسانی نیز پرداختیم.

در بسیاری از مطالعات که در راستای طبقه‌بندی بافت پستان انجام‌شده، داده‌های مورد بررسی به دو گروه سالم و سرطانی تقسیم‌شده‌اند. در مطالعات محدودی نیز بر اساس نوع دادگان مورد بررسی به سه یا چند گروه، طبقه‌بندی شده‌اند. انواع طبقه‌بندی مورد استفاده در این مطالعات را نیز می‌توان به دو گروه کلی مدل‌های ML و یادگیری عمیق<sup>۱۴</sup> (DL) تقسیم کرد [۲۵-۲۷].

برخی فواید DL عبارتند از:

- انعطاف‌پذیری بالا: شبکه‌های عصبی عمیق می‌توانند برای انواع مختلف تصاویر پزشکی به کار روند و به راحتی قابل تنظیم هستند. این ویژگی باعث می‌شود که این روش‌ها برای کاربردهای مختلف پزشکی قابل استفاده باشند [۲۸].
- دقت کلی: اگرچه ممکن است دقت کلی یک مدل DL در مقایسه با SVM کمتر باشد، اما با افزایش حجم داده‌های آموزشی و بهبود معماری شبکه‌ها، می‌توان به دقت‌های بالاتری دست‌یافت [۲۹].
- قابلیت تعمیم: مدل‌های DL معمولاً قابلیت تعمیم بهتری نسبت به SVM دارند، به این معنی که می‌توانند بر روی داده‌های جدید و دیده‌نشده عملکرد بهتری داشته باشند [۲۸].

در جدول (۱) خلاصه‌ای از پژوهش‌های مرتبط انجام‌شده شامل نام دادگان مورد بررسی، تعداد گروه‌ها و در نهایت نوع طبقه‌بندی مورد استفاده برای ضایعه‌های پستان گزارش شده‌است. همچنین بر مبنای پژوهش مروری [۳۰]، تعداد مراجع چاپ‌شده و مطالعات انجام‌شده در زمینه‌ی سرطان پستان بر پایه‌ی DL در سال‌های ۲۰۱۵ تا ۲۰۲۱ در شکل (۱) به صورت خلاصه نشان داده شده‌است.

در مورد بافت پستان، علاوه بر طبقه‌بندی انواع ضایعه‌های آن، در برخی پژوهش‌ها به درجه‌بندی بافت بر اساس تراکم [۳۱] یا تعیین درجه‌ی ضایعه‌ای خاص پرداخته شده‌است. یکی از شایع‌ترین نوع سرطان، سرطان مجرای شیری است [۲۹].

ارتجاع‌نگاری ایستا<sup>۸</sup> که در تخمین جابه‌جایی، فقط جابه‌جایی بافت در حالت تثبیت‌شده پس از اعمال نیروی ثابت را مورد بررسی قرار می‌دهد، ارتجاع‌نگاری پویا این امکان را می‌دهد تا جابه‌جایی بافت در طول زمان و در پاسخ به ارتعاشات و حرکات بررسی شود. بررسی تغییرات ساختاری در مراحل مختلف زمانی، ارزیابی تاثیر روش‌های درمانی، تحلیل و بررسی فعالیت عصبی و عضلانی و غیره [۲۱] از جمله کاربردهای این روش ارتجاع‌نگاری هستند.

ایراد استفاده از روش‌های مختلف ارتجاع‌نگاری که جزو محدودیت‌های این روش نیز می‌باشد، بررسی تغییرات ایجاد شده در شکل بافت و یا دنبال کردن جابه‌جایی‌ها برای تخمین پارامترهای مختلف است. این مساله علاوه بر نیاز به دقت بالا برای تخمین جابه‌جایی و پیچیدگی محاسباتی برای تخمین پارامترهای مختلف یک مدل، این محدودیت را دارد که هر مدل تنها بخشی از ویژگی‌های یک سیستم را آشکار می‌کند.

ما در سال ۲۰۲۰ روش RFTSDP را ارائه دادیم که با ایجاد تحریک، تغییرات موجود در پاسخ دینامیکی بافت‌های مختلف را در سیگنال‌های بازگشتی نمایان می‌سازد [۲۲، ۲۳]. در واقع، در این روش ضمن استفاده از مزیت‌های روش ارتجاع‌نگاری پویا، به پردازش دقیق‌تر سیگنال‌های بازگشتی پرداخته می‌شود. در این روش به جای دنبال کردن حرکت، تغییرات ایجادشده در سیگنال‌های بازگشتی مورد پردازش قرار می‌گیرد که الگوهای حرکتی پراکنده‌کننده‌های بافت نقش اصلی را در آن‌ها ایفا می‌کنند.

همچنین تاثیر برخی از پارامترهای ثبت، مانند عمق فوکوس، ناحیه مورد نظر<sup>۹</sup> (ROI) و فرکانس مرکزی کاوش‌گر<sup>۱۰</sup> بر نتایج طبقه‌بندی در روش RFTSDP بررسی شد [۲۳]. در پژوهش [۲۴] به ارزیابی روش RFTSDP برای طبقه‌بندی چهار فانتوم از ضایعه‌های سرطانی و غیرسرطانی پستان پرداخته شد. استخراج ویژگی‌ها در حوزه‌های مختلف و استفاده از روش‌های مختلف طبقه‌بندی یادگیری ماشین<sup>۱۱</sup> (ML) به روش سنتی انجام شد.

بهترین نتایج مربوط به داده‌های بیم‌فرم‌شده<sup>۱۲</sup> ی فوق سریع<sup>۱۳</sup> (BF UF)، استفاده از ویژگی‌های طیفی و غیرخطی و طبقه‌بندی SVM بود. طبق نتایج این مطالعه، با بهره‌گیری از روش RFTSDP و بررسی داده‌های BF UF امکان طبقه‌بندی چهار نوع ضایعه با دقت ۹۸/۴۴ فراهم شد. همچنین نتایج نشان

<sup>11</sup> Machine Learning

<sup>12</sup> Beamformed

<sup>13</sup> Ultrafast

<sup>14</sup> Deep Learning

<sup>8</sup> Static

<sup>9</sup> Region of Interest

<sup>10</sup> Probe

- در این پژوهش از روش ثبت و پردازش جدیدی با نام RFTSDP به منظور تعیین نوع بافت استفاده شد. در این روش سری زمانی RF از داده‌هایی که در حین اعمال انواع تحریک به بافت ثبت شده‌اند، ساخته می‌شود.
- در این مطالعه، به جای استفاده از فانتوم‌های همگن، بررسی روش معرفی شده روی داده‌های UF ثبت شده از نمونه بافت‌های طبیعی خارج شده از پستان، انجام گرفته است.
- نوآوری دیگر این پژوهش در راستای تعیین نوع بافت می‌باشد. تلاش ما بر این بود که با استفاده از روش RFTSDP بتوان به اطلاعات بیشتری از محیط انتشار امواج دست‌یافت و تشخیص نوع ضایعه‌های غیرسرطانی، علاوه بر تفکیک بافت‌های سالم و سرطانی، میسر شود. نتایج این پژوهش نشان داد که با اطلاعات به دست آمده، علاوه بر توانایی ذکر شده می‌توان درجه‌بندی ضایعه‌های سرطانی را با دقت خوبی دنبال کرد.
- در این مطالعه برای دست‌یابی به عملکرد دقیق‌تر و مدل پایدارتر از DL به منظور استخراج خودکار ویژگی و طبقه‌بندی انواع ضایعه‌های پستان بهره جستیم و نتایج آن را با SVM مقایسه کردیم.

ساختار کلی این مقاله به شرح زیر است: بخش ۲ توصیف انواع بافت‌های خارج شده‌ی پستان و ساخت فانتوم‌ها، اعمال تحریک‌های مختلف و شرایط ثبت داده‌ها را پوشش می‌دهد. بخش ۳ روش‌های ایجاد سری زمانی، پردازش داده‌ها، روش‌های استخراج ویژگی و طبقه‌بندی را شرح می‌دهد. بخش ۴ به ارزیابی عملکرد روش پیشنهادی و بحث در مورد یافته‌ها می‌پردازد. در نهایت، بخش ۵ نتیجه‌گیری‌های کلی از این پژوهش را ارائه می‌دهد.

## ۲- مواد

در این مقاله، به منظور ارزیابی کامل‌تر روش RFTSDP، داده‌های حالت BF UF در تحریک‌های مختلف از بافت‌های برون-تنی انسانی جمع‌آوری شدند. در این بخش، مراحل مربوط به نحوه‌ی اعمال تحریک، ساخت فانتوم و ثبت داده‌ها شرح داده شده‌اند.


### ۲-۱- لرزاننده و پایه‌ی نگاه‌دار

همان‌طور که ذکر شد، ایده‌ی اصلی RFTSDP بر پایه‌ی اعمال تحریک خارجی است. روش‌های مختلفی برای اعمال تحریک خارجی در ارتجاع‌نگاری وجود دارد که بر اساس نوع بافت، نحوه‌ی اعمال تحریک و بازه‌ی فرکانسی مورد نیاز متفاوت است [۴۲-۴۶]. هدف اصلی این تحریک‌کننده‌ها، ایجاد تغییرات

معمولاً نمره‌ای بین یک تا سه به این سرطان اختصاص داده می‌شود که تعیین کننده‌ی درجه‌ی کلی آن است [۳۲، ۳۳].

**جدول (۱)** - خلاصه‌ای از نام دادگان، تعداد گروه‌ها و در نهایت نوع طبقه‌بند مورد استفاده برای ضایعه‌های پستان.

طبقه‌بند	تعداد گروه‌ها	مرجع و داده‌ها
DL (CNN)	۸	BreakHis [۳۴]
DL (CNN)	۱۰	MIAS [۳۵]
DL	۸ یا ۲	BreakHis [۲۵]
DL (CNN)	۲	TCGA [۳۶]
DL (CNN GNN)	۲	BUSI, BUS, and OASBUD [۳۷]
DL	۲	Self pro [۳۸]
DL	۲	Self pro [۳۹]
DL (CNN)	۲	Self pro [۴۰]



**شکل (۱)** - تعداد مراجع چاپ شده و مطالعات انجام شده در زمینه‌ی سرطان پستان بر پایه‌ی DL طی هفت سال [۴۱].

در پژوهش‌های انجام شده در حوزه‌ی RFTSDP به دلایل مختلف از جمله کمبود داده امکان استفاده از DL فراهم نبود [۲۲-۲۴]. در این پژوهش با افزایش نمونه‌های انسانی خارج شده از بافت پستان و افزایش تعداد سری‌های زمانی، از DL هم برای استخراج ویژگی به صورت خودکار و هم برای طبقه‌بندی استفاده شد. همچنین نتایج آن با نتایج به دست آمده با استفاده از ML مقایسه شده است. به این ترتیب در این پژوهش ما نیز مشابه با مطالعات خلاصه شده در جدول (۱)، از CNN برای طبقه‌بندی انواع ضایعه‌های پستان و درجه‌بندی ضایعه‌های سرطانی بهره جستیم. اصلی‌ترین نوآوری‌های این مطالعه در ادامه خلاصه شده است:

نگهداری لرزاننده و کاوش‌گر در ثبت‌های بدون اعمال تحریک و تحریک ایستا که در بخش ۳-۲ توضیح داده شده نیز یک پایه‌ی نگهدار طراحی شد. سیستم طراحی شده برای اعمال انواع تحریک مورد نیاز در این پژوهش در شکل (۲) نمایش داده شده است.

## ۲-۲- بافت‌های خارج شده از پستان و فانٹوم‌ها

روش جدید پیشنهادی نیاز به بررسی دقیق تر در شرایط طبیعی را دارد. به دلیل جدید بودن این ایده در گام بعدی بررسی باید روی داده‌های طبیعی برون‌تنی انجام می‌شد. در این پژوهش با همکاری با بیمارستان مهر، بیمارستان قائم و بیمارستان پارسیان، ۱۱ نمونه بافت برون‌تنی پستان بعد از مشخص شدن نتایج پاتولوژی آن‌ها در اختیار ما قرار گرفت. این بافت‌ها شامل چهار نمونه بافت سالم و هفت نمونه از بافت ضایعه‌های گوناگون از جمله نکروز چربی<sup>۱۵</sup>، سرطان مهاجم با منشا مجاری شیری<sup>۱۶</sup> (IDC) با درجه‌ی دو و سه و سرطان مهاجم با منشا سلول شیری<sup>۱۷</sup> (ILC) بود. با توجه به تنوعی که این بافت‌ها داشت امکان گروه‌بندی‌های مختلف را فراهم می‌کرد که در این مطالعه به بررسی طبقه‌بندی انواع ضایعه‌ی سالم و غیرسرطانی و سرطانی و همچنین درجه‌بندی ضایعه‌ی سرطانی به پنج گروه زیر پرداختیم: پنج گروه (سالم، نکروز چربی، IDC گرید دو و سه و ILC).



شکل (۲) - تصویر بالا: نحوه‌ی قرارگیری پایه‌ی نگهدار، کاوش‌گر و لرزاننده روی سطح فانٹوم [۲۴]. تصویر پایین: پایه‌ی نگهدار طراحی شده برای ثبت از نمونه بافت‌های خارج شده.

قابل مشاهده در تصویر با ایجاد لرزش در بافت و بررسی امواج فرستاده شده توسط لرزاننده و بازتاب شده از بافت است. این تغییرات می‌توانند شامل جابه‌جایی دیواره‌های بافت، حرکت ساختارهای داخلی بافت و تغییرات شدت و شکل بازتاب‌ها باشند [۲۳].

در بسیاری از روش‌های ارتجاع‌نگاری ایستا، میزان نیرو، اندازه-گیری و گزارش نمی‌شود بلکه فقط به صورت مقایسه‌ای میزان جابه‌جایی قسمت‌های مختلف نسبت به هم بررسی شده و به عنوان نقشه‌ای نسبی از میزان سفتی بافت نسبت به بخش‌های مختلف ارائه می‌شود [۴۷-۴۹]. یکی از مشکلات روش ارتجاع‌نگاری ایستا این است که اگر نیروی کمی وارد شود، اختلاف جابه‌جایی ایجاد شده بین انواع بافت کم خواهد بود و اگر برای افزایش تضاد، نیرو را افزایش دهند، رفتار بافت تغییر کرده و یافتن قله‌های همبستگی دو سیگنال RF بسیار سخت خواهد شد [۵۰].

در روش RFTSDP نیازی به یافتن پارامتر همبستگی و محاسبه‌ی جابه‌جایی نیست و نقش اصلی را الگوهای بازگشتی سیگنال RF بازی می‌کند که در بافت‌های مختلف، متفاوت خواهد بود. به این ترتیب در ایده‌ی این پژوهش نیز اندازه‌گیری مقدار دقیق نیروی اعمالی در بخش‌های مختلف ضروری نیست و بحث یکسان بودن آن بر اساس میزان نسبی جابه‌جایی اهمیت بیش‌تری دارد. در این پژوهش برای ثبت‌های ایستا که نیاز به اعمال نیروی ثابت به نمونه است، از یک گیره‌ی نگهدار علامت-گذاری شده استفاده شده است.

نکته جالب توجه این است که در روش ارتجاع‌نگاری لرزشی لازم است برای سرکوب نیروی عکس‌العمل بافت در مقابل لرزاننده تدبیری در نظر گرفته شود زیرا در میزان جابه‌جایی اندازه‌گیری شده موثر است [۵۱]. در صورتی که در روش RFTSDP بحث جابه‌جایی مطرح نیست بنابراین نیازی به سیستم جذب لرزش نیز وجود ندارد.

در [۲۴] اشاره شده که برای اعمال تحریک لرزشی در فرکانس دلخواه، لرزاننده‌ای ساده از نوع پیستونی طراحی شد. برای انجام ثبت‌های انسانی و ثبت‌های این پژوهش موتور استفاده شده در این لرزاننده ارتقا یافت تا بتواند بازه‌ی فرکانسی بیشتری را برای ایجاد لرزش پوشش دهد. برای این منظور از یک موتور دی‌سی گیربکس دار GA-37025 (محصول کشور تایوان) به همراه یک انکدر نوری برای تعیین سرعت حرکت موتور و در نهایت فرکانس لرزشی که ایجاد می‌کند، استفاده شد. همچنین برای

<sup>۱۷</sup> Invasive Lobular Carcinoma

<sup>۱۵</sup> Fat necrosis

<sup>۱۶</sup> Invasive Ductal Carcinoma

ردیابی حرکت، به منظور ثبت پاسخ‌های دینامیکی بافت در حین اعمال تحریک انتخاب‌شد.

در ثبت ساده برای ثابت بودن کاوش‌گر و در تحریک ایستا برای حفظ فشار ثابت عمود بر بافت، از یک پایه‌ی نگهدار با ارتفاع قابل تنظیم استفاده‌شد. در حالت تحریک لرزشی یک لرزاننده ساخته و با استفاده از پایه‌ی نگهدار در دو سانتی‌متری کاوش‌گر فراصوت روی سطح فانتوم قرار داده‌شد (شکل ۲). این تجهیزات در تحریک لرزشی با فرکانس‌های ۱۵ تا ۷۵ هرتز، با افزایش گام ۱۰ هرتز، مورد استفاده قرار گرفت. پارامترهای ثبت، از جمله عمق تصویر، عمق فوکوس و فرکانس مرکزی کاوش‌گر، بر اساس تحقیقات قبلی به ترتیب ۴، ۲ سانتی‌متر و ۶٫۴ مگاهرتز تنظیم شدند [۲۲، ۲۳]. نرخ قاب در حالت UF روی ۵۰۰۰ قاب بر ثانیه تنظیم شد که تعداد ۱۲۸ قاب را در هر تصویربرداری ذخیره می‌کند.

### ۳- روش‌ها

در این بخش به روش‌هایی که در گام بعد از ثبت داده برای شکل‌گیری سری‌های زمانی و پردازش آن‌ها صورت می‌گیرد، اشاره شده‌است. در بخش ۳-۱ نحوه‌ی انتخاب ROI، تشکیل سری‌های زمانی و ورودی شبکه مشخص شده‌است. همچنین همان‌طور که ذکر شد در این مطالعه از روش DL به منظور استخراج خودکار ویژگی و طبقه‌بند استفاده‌شد. ML معمولاً از ویژگی‌های مهندسی‌شده استفاده می‌کند که توسط انسان تعریف می‌شوند [۵۷]. این ویژگی‌ها ممکن است برای برخی از مسایل بسیار کارآمد باشند، اما ممکن است نتوانند پیچیدگی‌های موجود در داده‌های واقعی را به طور کامل پوشش دهند [۲۸]. در نتیجه، مدل‌های سنتی یادگیری ماشین ممکن است در تعمیم به داده‌های جدید با مشکل مواجه شوند.

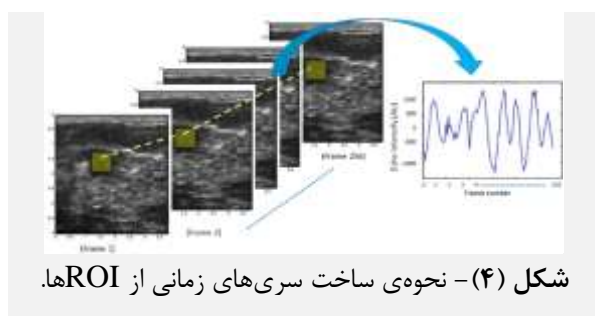
در بحث طبقه‌بندی، نتایج بهینه‌ی استفاده از ویژگی‌ها به انتخاب درست نوع طبقه‌بند نیز وابسته می‌باشد [۲۷]. از طرفی DL به دلیل ساختار پیچیده و لایه‌های متعدد خود، پتانسیل بالایی برای یادگیری ویژگی‌های پیچیده و انتزاعی از داده‌ها دارد. این ویژگی باعث می‌شود که مدل‌های DL بتوانند الگوهای پیچیده‌تری را در داده‌ها شناسایی کنند و در نتیجه، قابلیت تعمیم بهتری داشته‌باشند [۲۸]. به این ترتیب با استفاده از DL، مدل پایدارتری در روش RFTSDP حاصل می‌شود که به ویژه برای داده‌های بالینی نتایج بهتری را در طبقه‌بندی خواهد داشت.

با توجه به اندازه‌ی بافت‌ها و مشابه شدن شرایط ثبت به شرایط واقعی، لازم بود این نمونه‌ها درون شبیه‌ساز بافت سالم پستان قرار گیرند و بعد انواع ثبت‌های مورد نیاز ما انجام‌گیرد. پلی-وینیل‌الکل در بسیاری از مراجع به عنوان بهترین ماده‌ی شبیه-ساز خواص مکانیکی و صوتی بافت‌های مختلف پستان معرفی-شده‌است [۵۲-۵۵]. در این پژوهش امکان استفاده از این نوع فانتوم‌ها فراهم نبود زیرا امکان نگهداری سالم بافت انسانی در چرخه‌های مختلف انجماد و ذوب با تغییرات دمایی و ساختاری که در فانتوم ایجاد می‌شد، وجود نداشت. به این ترتیب از فانتوم‌های بر پایه‌ی آگار-ژلاتین برای شبیه‌سازی بافت سالم و قرار گرفتن بافت‌های انسانی درون آن استفاده‌شد.

فانتوم‌های ژلاتین و آگار در تایید و آزمایش روش‌های ارتجاع-نگاری [۴۲]، بررسی سری‌های زمانی RF [۸، ۱۶، ۱۹] و RFTSDP [۲۲، ۲۳] موفقیت‌آمیز بوده‌اند. در این پژوهش، یازده فانتوم آگار-ژلاتین از بافت سالم با ضریب ارتجاعی گزارش شده در [۲۲، ۲۳] ساخته شدند. درصد مشخصی از سلولز نیز به فانتوم‌ها اضافه‌شده [۱۶، ۵۵، ۵۶] تا الگوی لکه‌مانند بافت سالم پستان را شبیه‌سازی کند. برای نگهداشتن فانتوم در دمای اتاق، ضدقارچ به محلول اضافه‌شد. سپس دوسوم مواد در قالب استوانه‌ای پرسپکس با قطر و ارتفاع پنج سانتی‌متر برای هر فانتوم ریخته‌شد. پیش از این که فانتوم‌ها کاملاً سفت شود و به دمای اتاق برسد، بافت انسانی در وسط ظرف قرار گرفته و باقی مواد نیز داخل قالب ریخته‌شد. قالب داخل یخچال قرار گرفته و بعد از ۲۴ ساعت فانتوم از قالب جدا شد. در نهایت سیگنال‌های بازگشتی RF با تحریک‌های متفاوت از هر یک از فانتوم‌ها ثبت‌شد.

### ۳-۲- ثبت داده

در این پژوهش داده‌های RF با استفاده از سیستم تصویربرداری فراصوت بالینی/تحقیقاتی سوپرسونیک مجهز به کاوش‌گر خطی SuperLinear™ SL18-5 ضبط شدند. برای افزایش تاثیر خصوصیات دینامیکی بافت بر سیگنال‌های بازگشتی RF، روش‌های تحریک مختلفی اعمال شد، از جمله روش ساده (کاوش‌گر ثابت بدون اعمال نیرو)، ایستا (نیروی ثابت در طول ثبت) و حالت لرزشی. هر یک از داده‌ها در حالت BF UF جمع‌آوری شدند. اگرچه در روش RFTSDP دنبال کردن حرکت اهمیت ندارد و حتی در این روش دنبال کردن اسپیکل نیز مد نظر نیست اما دنبال کردن تغییرات ایجاد شده در الگوی بازگشتی سیگنال‌های RF که متاثر از لرزش و جابه‌جایی پراکنده‌کننده‌هاست، اهمیت زیادی دارد. بنابراین حالت UF در این پژوهش، با سرعت تصویربرداری بالاتر و توانایی بهتر در



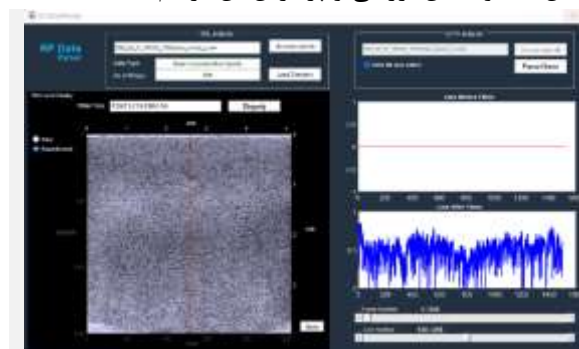
هر ROI نماینده‌ی یک ویژگی باشد، هر ROI شامل ۱۹۲ سری زمانی بوده که هر کدام به عنوان یک ورودی مجزا برای شبکه در نظر گرفته‌شد. با توجه به ایده‌ی اصلی مطرح شده در این روش که به بررسی زمانی سیگنال RF می‌پردازد و نگاه فضایی به آن ندارد، تفکیک سیگنال‌های موجود در فضای ROI و برجسب داشتن هر یک به صورت مجزا در این روش کاملاً توجیه‌پذیر است. به این ترتیب تعداد مناسب ورودی از هر نمونه بافت انسانی شامل چهار نمونه بافت سالم، دو نمونه از هر یک از ضایعه‌های نکروز چربی، سرطان مهاجم مجاری شیری با درجه‌ی دو و سه و یک نمونه سرطان مهاجم غدد شیری وجود داشت. در مجموع در هر پنج گروه ۶۷۵۸۴ ورودی برای آموزش و آزمایش شبکه که بیست درصد کل داده‌ها برای آزمایش و بقیه برای آموزش و اعتبارسنجی در نظر گرفته‌شد.

### ۳-۲- استخراج ویژگی و طبقه‌بندی

همان‌طور که ذکر شد در پژوهش‌های انجام‌شده در راستای ارزیابی RFTSDP، استخراج ویژگی در حوزه‌های مختلف از سری زمانی صورت گرفته‌است. روش‌های مختلف ML نیز به عنوان طبقه‌بند استفاده‌شده‌است [۲۲-۲۴]. نتایج این تحقیقات نشان داد، بررسی ویژگی‌های حوزه‌ی طیفی و غیرخطی، امکان توصیف بهتری از تفاوت عملکرد بافت‌ها را در این روش RFTSDP فراهم می‌کند. همچنین SVM نیز در انواع طبقه‌بندی با کلاس‌های مختلف بهترین نتایج را ارائه کرده‌است. DL به ویژه شبکه‌های عصبی کانولوشنی<sup>۱۹</sup> (CNN)، در سال‌های اخیر به عنوان یک ابزار قدرتمند برای تحلیل تصاویر پزشکی، مورد توجه قرار گرفته‌است [۲۷، ۳۰]. CNNها قادرند به صورت خودکار ویژگی‌های پیچیده و مرتبط با بیماری را از تصاویر استخراج کنند. این ویژگی باعث می‌شود که این روش‌ها به داده‌های برجسب‌گذاری شده کمتری نیاز داشته‌باشند و در عین حال به دقت بالاتری دست‌یابند [۲۷]. در اکثر مراجع ذکر شده در جدول (۱) نیز از CNN به منظور طبقه‌بندی انواع گروه‌های ضایعه‌ی پستان در مجموعه دادگان مختلف بهره‌برده‌اند. این حقیقت که این معماری کاربرد خوبی در بحث تعیین

### ۳-۱- تشکیل سری‌های زمانی RF

داده‌های RF به‌دست‌آمده از دستگاه سوپرسونیک با فرمت خاصی ذخیره می‌شود. یک رابط کاربری گرافیکی<sup>۱۸</sup> (GUI) مبتنی بر متلب به نام RF Data Parser (شکل (۳))، توسعه یافت تا داده‌ها را به فرمت فایل mat تبدیل کرده و تصویر نهایی مد بی را نیز نمایش می‌دهد. این ابزار همچنین امکان اعمال فیلترهای مختلف به داده‌های RF و مد بی را فراهم می‌کند. تمامی ثبت‌های انجام‌شده با استفاده از این نرم‌افزار تبدیل شده و امکان بررسی و پردازش آن فراهم‌شد.



شکل (۳) - شمای کلی GUI طراحی شده برای تبدیل داده‌های ثبت‌شده با سوپرسونیک.

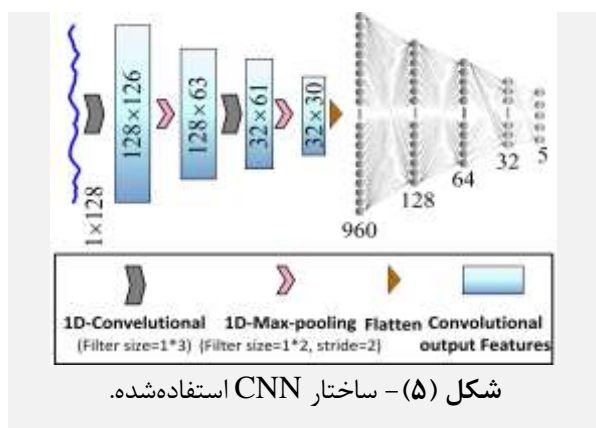
فرآیند ضبط داده از چهار ناحیه مجزا بر روی سطح هر فانتوم انجام‌شد. در این نواحی، هشت ROI در عمق مشخص برای هر قاب شناسایی شد. با قرار دادن دنباله‌ی نقاط مشخص هر ROI در قاب‌های مختلف، سری‌های زمانی ساخته‌شد (مطابق شکل (۴)).

هر ROI با ابعاد ۱ میلی‌متر × ۱/۵ میلی‌متر و شامل چهار در ۴۸ (۱۹۲) سری زمانی می‌باشد. به این ترتیب اثر لرزش و جابه‌جایی پراکنده‌کننده‌های هر نقطه که در سیگنال بازگشتی نمایان شده، دنبال می‌شود. لازم به ذکر است طول هر سری زمانی ایجادشده برابر عداد قاب‌های ذخیره‌شده می‌باشد.

در مطالعات قبلی [۲۲-۲۴] که ویژگی‌های حوزه‌های مختلف از سری‌های زمانی استخراج شد، ویژگی مورد نظر برای هر سری زمانی محاسبه شده و در نهایت درون هر ROI میان‌گیری شدند. به عبارت دیگر هر ROI مشخص‌کننده‌ی یک ویژگی بوده‌است. با توجه به نمونه‌های بافت انسانی، تعداد ورودی‌های طبقه‌بندهای ML برابر ۳۲ در ۱۱ بود. تعداد این نمونه‌ها برای ورودی شبکه‌های DL بسیار کم است و طبق مستندات ذکرشده این نوع شبکه‌ها نیاز به داده‌های زیاد دارند [۲۴]. برای آماده‌سازی داده‌های ورودی شبکه به جای این که

<sup>۱۹</sup> Convolutional Neural Network

<sup>۱۸</sup> Graphical User Interface



### ۳-۳- ارزیابی عملکرد طبقه‌بنده

در راستای مقایسه‌ی نتایج حاصل از این پژوهش با مطالعات پیشین در حوزه‌ی RFTSDP، عملکرد مدل CNN در برابر SVM، که در [۲۲-۲۴] به عنوان یکی از برترین روش‌های طبقه‌بندی معرفی شده، ارزیابی شد. همان‌گونه که در بخش ۳-۱ تشریح گردید، به منظور افزایش تنوع داده‌های مورد استفاده در آموزش شبکه، هر سری زمانی به عنوان یک ورودی مستقل به مدل CNN ارائه شد. برای حصول اطمینان از امکان مقایسه دقیق و معتبر، فرایند ارزیابی SVM نیز با محاسبه‌ی جداگانه ویژگی‌های طیفی و غیرخطی مرتبط با هر سری زمانی انجام پذیرفت. این تدابیر، امکان مقایسه‌ی منصفانه‌ی عملکرد مدل‌های ML و DL را با حفظ تعداد ورودی‌های یکسان فراهم ساخت.

جهت ارزیابی طبقه‌بنده‌ها، ابتدا ۲۰ درصد داده‌ها به عنوان داده‌ی آزمایش در هر دو روش ML و DL جدا شدند. برای اعتبارسنجی SVM از روش  $K\text{-fold}=8$  استفاده شد. با توجه به نامتعادل بودن تعداد داده‌ها در گروه‌ها، در هر دو مرحله‌ی اعتبارسنجی و آزمایش از تقسیم‌بندی طبقه‌ای<sup>۲۵</sup> برای جداسازی داده‌ها و دسته‌بندی آن‌ها استفاده شد. این روش تضمین می‌کند که هر کلاس به نسبت مشابهی در داده‌های آموزشی، اعتبارسنجی و آزمایش وجود داشته‌باشد.

همچنین برای بالا بردن دقت کار و ارایه‌ی نتایج پایدارتر، هر یک از طبقه‌بندی‌ها به صورت کامل ۱۰ بار تکرار شد و نتایج با انحراف معیار در جدول‌ها و نوار خطا<sup>۲۶</sup> در شکل‌ها گزارش شده‌اند. برای ارزیابی عملکرد روش پیشنهادی در طبقه‌بندی، شش شاخص عملکرد مورد بررسی قرار گرفت. در نهایت نیز نتایج بدست آمده از CNN در روش پیشنهادی با نتایج SVM در همین روش و نتایج مقاله‌های قبلی در حوزه‌ی تعیین نوع بافت

سرطان پستان دارد نیز در شکل (۱) نشان داده شده است [۳۰]. با توجه به این که داده‌های این پژوهش توالی‌های یک‌بعدی هستند، استفاده از CNN یک‌بعدی مناسب بود. به این ترتیب ما نیز از CNN یک‌بعدی برای تعیین الگوها و ویژگی‌ها در طول توالی بهره جستیم. ابتدا معماری پنج لایه‌ای از CNN به همراه یک لایه مسطح<sup>۲۰</sup> برای داده‌ها استفاده شد. اما نتایج به دست آمده با این معماری قابل قبول نبود و شبکه‌های آموزش دیده دچار بیش‌برازش می‌شدند و با روش‌های مختلف هنجارسازی داده‌ها، تغییرات جزئی ساختار شبکه، هایپر پارامترها، تعداد لایه‌ها و تغییر تابع هزینه، نتیجه‌ی دلخواه حاصل نشد. به این ترتیب معماری دیگری در نظر گرفته شد. برای این منظور یک CNN چهار لایه به همراه لایه‌های تجمیع<sup>۲۱</sup> پیاده‌سازی شد که توسط لایه‌های مسطح و لایه‌های فشرده<sup>۲۲</sup> برای طبقه‌بندی نهایی دنبال می‌شود. معماری شبکه‌ی جدید در شکل (۵) نشان داده شده است. برای بهینه‌سازی هایپرپارامترها، از یک روش ترکیبی استفاده شد که شامل آزمایش‌های دستی با رویکرد جستجوی آگاهانه بر اساس دانش قبلی و پیشنهادات موجود در مقالات و منابع معتبر و بهره‌گیری از ابزارهای هوشمند برای تسریع فرایند جستجو و یافتن مقادیر مناسب بود. در ادامه به جزئیات بیشتری در مورد ساختار و پارامترهای شبکه اشاره شده است.

ورودی مدل توالی‌هایی با طول ۱۲۸ و خروجی آن، احتمال تعلق هر توالی به یکی از پنج گروه است. همان‌طور که در شکل (۵) نیز نشان داده شده تعداد ویژگی‌های استخراج شده توسط لایه‌های اصلی شبکه ۹۶۰ بوده که توسط لایه‌های فشرده برای طبقه‌بندی پنج گروه استفاده می‌شود. اندازه‌ی فیلتر سه انتخاب شده، این اندازه به مدل اجازه می‌دهد الگوهای محلی را در طول توالی تشخیص دهد و نسبت به دیگر مقادیر بزرگ‌تر که مورد بررسی قرار گرفت، نتایج بهتری را ایجاد کرد. تابع فعال‌سازی واحد خطی یکسوشده<sup>۲۳</sup> (ReLU) به دلیل سرعت آموزش بالا و جلوگیری از مشکل محوشدگی گرادیان<sup>۲۴</sup> انتخاب شد [۵۸، ۵۹]. تجمیع بیشینه با اندازه پنجره دو انتخاب شد. این لایه ابعاد داده‌ها را کاهش می‌دهد و ویژگی‌های مهم را حفظ می‌کند [۶۰]. تعداد نورون‌ها در لایه‌های کاملاً متصل (۱۲۸، ۶۴، ۳۲) به تدریج کاهش یافته است. این کار به کاهش پیچیدگی مدل و جلوگیری از بیش‌برازش کمک می‌کند [۵۹].

<sup>۲۴</sup> Vanishing Gradient

<sup>۲۵</sup> Stratified Partitioning

<sup>۲۶</sup> Error Bar

<sup>۲۰</sup> Flatten

<sup>۲۱</sup> Max pooling

<sup>۲۲</sup> Dense

<sup>۲۳</sup> Rectified Linear Unit

پژوهش را بهتر فراهم می‌کند. به این ترتیب در روش DL نیز تمامی نتایج ذکر شده برای داده‌های BF UF ارایه شده است. معماری ذکر شده در شکل (۵) برای ارزیابی داده‌های انسانی بیم‌فرم شده با انواع تحریک مورد استفاده قرار گرفت. در این پژوهش با توجه به نوع ضایعه‌هایی که در اختیار ما قرار گرفت، طبقه‌بندی پنج گروه مختلف بررسی شد. در طبقه‌بندی پنج گروه علاوه بر طبقه‌بندی انواع ضایعه‌های سرطانی و غیرسرطانی، درجه‌بندی یک ضایعه‌ی غیرسرطانی نیز انجام شده که در بخش ۲-۲ به آن اشاره شده است. در ادامه نتایج حاصل از بررسی شبکه‌ی طراحی شده در این طبقه‌بندی ارایه شده است.

#### ۱-۴- ارزیابی عملکرد شبکه

جدول (۲) برای ارزیابی RFTSDP با تحریک‌های مختلف و شاخص‌های مختلف عملکرد شبکه‌ی طراحی شده، تهیه شده است. شاخص‌های مختلف در این جدول به صورت درصد میانگین  $\pm$  انحراف استاندارد که پس از ۱۰ تکرار هر طبقه‌بندی کامل به دست آمده، گزارش شده‌اند. با جدا کردن نوع تحریک در جدول (۲) مشخص شد که استفاده از تحریک لرزشی با فرکانس مناسب در روش RFTSDP نه تنها طبقه‌بندی انواع بافت و تعیین نوع ضایعه را بهبود می‌بخشد، بلکه در درجه‌بندی ضایعه نیز موفق بوده است.

طبق این نتایج، بهترین عملکرد مربوط به فرکانس لرزشی ۶۵ هرتز بوده و میانگین صحت و دقت حاصل شده برای این ثبت به ترتیب  $99/53 \pm 0/17$  و  $99/53 \pm 0/28$  درصد در طبقه‌بندی و درجه‌بندی پنج گروه بوده است. استفاده از یک معماری ساده در روش یادگیری به طور قابل توجهی این تفاوت را نشان داده و مشخص می‌کند اعمال لرزش در میزان بهبود صحت طبقه‌بندی بسیار موثر است.

طبق نتایج به دست آمده، میانگین صحت و دقت حاصل شده برای ثبت‌های لرزشی نسبت به حالت ساده و بدون اعمال تحریک به ترتیب  $23/22$  و  $21/60$  درصد بهبود یافته است. در این نوع طبقه‌بندی نیز بهترین نتایج مربوط به اعمال لرزش ۶۵ هرتز در بافت پستان بوده است.

با استفاده از سری زمانی مورد مقایسه قرار گرفت. این شاخص‌ها عبارتند از صحت<sup>۲۷</sup> (Acc)، فراخوان<sup>۲۸</sup> (Rec)، دقت<sup>۲۹</sup> (Pre)، امتیاز<sup>۳۰</sup> F (F<sub>Sc</sub>) و کاپا<sup>۳۱</sup> (Kap) که به شرح زیر تعریف می‌شوند:

$$Acc = \left( \frac{TP + TN}{TP + FP + TN + FN} \right) \times 100, \quad (1)$$

$$Rec = \left( \frac{TP}{TP + FN} \right) \times 100, \quad (2)$$

$$Pre = \left( \frac{TP}{TP + FP} \right) \times 100, \quad (3)$$

$$F_{Sc} = \frac{2 \times Pre \times Rec}{Pre + Rec} \times 100, \quad (4)$$

که TP، TN، FP و FN به ترتیب به معنای مثبت درست<sup>۳۲</sup>، منفی درست<sup>۳۳</sup>، مثبت کاذب<sup>۳۴</sup>، و منفی کاذب<sup>۳۵</sup> هستند [۶۱]. ضریب کاپا یک شاخص مهم برای ارزیابی مدل طبقه‌بندی است [۶۲]. کاپا را می‌توان از ماتریس درهم‌ریختگی<sup>۳۶</sup> با رابطه‌ی ۵ محاسبه کرد:

$$Kap = \left( \frac{Po - Pe}{1 - Pe} \right) \times 100, \quad (5)$$

که Po و Pe از روابط زیر به دست می‌آید.

$$Po = \left( \frac{TP + TN}{TP + FP + TN + FN} \right), \quad (6)$$

$$Pe = \frac{(TP + FN) \times (TP + FP) + (FP + TN) \times (FN + TN)}{(TP + TN + FP + FN)^2}$$

در این پژوهش همچنین به محاسبه‌ی شاخص همبستگی متیو<sup>۳۷</sup> (MCC) نیز پرداخته شده است. این شاخص یک معیار بسیار مفید برای اندازه‌گیری همبستگی بین مقادیر پیش‌بینی شده و مقادیر واقعی است و به عنوان یک معیار تعادل بخش بین انواع مختلف خطاها شناخته می‌شود [۶۳]. این مقیاس به طور خاص برای مقایسه‌ی پیش‌بینی‌های الگوریتم‌ها در طبقه‌بندی چندگروه مناسب است، زیرا به عواملی مانند تعداد کلاس‌ها و توزیع داده‌ها توجه می‌کند [۶۴]. لازم به ذکر است MCC فقط در صورتی امتیاز بالایی تولید می‌کند که پیش‌بینی‌ها نتایج خوبی را در هر دسته ماتریس درهم‌ریختگی داشته باشند [۶۵]. در حوزه پزشکی، جایی که تشخیص اشتباه می‌تواند عواقب جدی داشته باشد، MCC یک معیار بسیار مهم است [۶۴]. در ادامه به نتایج بررسی این شاخص‌ها پرداختیم.

#### ۴- یافته‌ها و بحث

بر اساس نتایج و بررسی‌هایی که تا کنون در روش RFTSDP انجام شده [۲۲-۲۴]، مد UF امکان ردیابی تاثیر تحریک بر الگوی پراکنده‌کننده‌ها و در نتیجه روش معرفی شده در این

<sup>33</sup> True Negative

<sup>34</sup> False Positive

<sup>35</sup> False Negative

<sup>36</sup> Confusion

<sup>37</sup> Mathew Correlation Coefficient

<sup>27</sup> Accuracy


<sup>28</sup> Recall

<sup>29</sup> Precision


<sup>30</sup> F-Score

<sup>31</sup> Kappa

<sup>32</sup> True Positive



شکل (۶) - تغییرات تابع هزینه و صحت در دوره‌های مختلف آموزش و آزمایش شبکه برای داده‌های انسانی در لرزش ۶۵ هرتز.



شکل (۷) - ماتریس درهم‌ریختگی شبکه‌ی طراحی شده برای داده‌های انسانی در لرزش ۴۵ و ۶۵ هرتز.

## ۲-۴- ارزیابی پایداری نتایج شبکه

برای مشخص‌تر شدن عملکرد شبکه در فرکانس ۶۵ هرتز، نمودارهای تابع هزینه و تغییرات صحت در دوره‌های مختلف آموزش و آزمایش شبکه نیز در شکل (۶) نشان داده شده‌است. ملاحظه می‌شود در آموزش و اعتبارسنجی این مدل، پیش از رسیدن به دوره‌ی ۳۰ شبکه به مقدار پایدار با صحت بسیار بالا رسیده‌است. از طرفی با توجه به ساده بودن معماری طراحی شده زمان آموزش نیز بسیار پایین است. علاوه بر این ماتریس درهم‌ریختگی برای مقایسه‌ی عملکرد شبکه در دو فرکانس مختلف نیز در شکل (۷) نشان داده شده‌است.

جدول (۲) - درصد شاخص‌های عملکردی CNN در سری زمانی داده‌های BF UF داده‌های انسانی.

نوع تحریک	Acc	Kap	Pre	F <sub>sc</sub>	Rec	Mcc
ساده	۸۵/۸۱±۴۲/۰	۳۶/۷۲±۶۹/۰	۷۷/۸۰±۵۶/۰	۰۷/۸۱±۲۹/۰	۳۵/۷۶±۶۱/۰	۴۸/۶۲±۳۵/۰
ایستا	۷۲/۷۵±۷۶/۰	۴۵/۵۱±۱۲/۰	۷۲/۶۷±۴۵/۰	۲۶/۷۱±۶۸/۰	۷۲/۶۷±۵۱/۰	۳۸/۵۲±۲۲/۰
لرزش ۱۵ هرتز	۱۷/۹۵±۳۳/۰	۱۱/۹۳±۵۶/۰	۱۵/۹۵±۴۲/۰	۱۳/۹۵±۴۵/۰	۱۵/۹۵±۱۰/۰	۱۲/۹۳±۵۶/۰
لرزش ۲۵ هرتز	۳۰/۹۵±۷۶/۰	۳۱/۹۳±۸۴/۰	۵۳/۹۲±۲۱/۰	۲۷/۹۵±۵۱/۰	۰۷/۹۴±۴۵/۰	۳۸/۹۳±۴۴/۰
لرزش ۳۵ هرتز	۵۱/۹۸±۸۱/۰	۸۵/۹۷±۵۵/۰	۴۹/۹۸±۴۵/۰	۵۰/۹۸±۶۲/۰	۴۹/۹۸±۷۱/۰	۸۵/۹۷±۴۱/۰
لرزش ۴۵ هرتز	۴۱/۹۸±۹۸/۰	۷۳/۹۷±۵۲/۰	۴۰/۹۸±۴۵/۰	۴۴/۹۸±۳۳/۰	۴۰/۹۸±۴۱/۰	۷۳/۹۷±۵۰/۰
لرزش ۵۵ هرتز	۹۱/۹۸±۲۵/۰	۴۴/۹۸±۷۸/۰	۹۱/۹۸±۸۵/۰	۹۱/۹۸±۴۸/۰	۹۱/۹۸±۷۴/۰	۴۴/۹۸±۳۴/۰
لرزش ۶۵ هرتز	۵۳/۹۹±۲۸/۰	۳۳/۹۹±۶۱/۰	۵۳/۹۹±۱۷/۰	۵۳/۹۹±۳۳/۰	۲۵/۹۹±۳۸/۰	۳۳/۹۹±۵۲/۰
لرزش ۷۵ هرتز	۴۴/۹۹±۴۶/۰	۲۰/۹۹±۵۲/۰	۴۴/۹۹±۲۲/۰	۴۴/۹۹±۳۳/۰	۱۷/۹۹±۵۶/۰	۲۰/۹۹±۶۸/۰

بررسی قرار گرفت و در نمودار (۸) نمایش داده شده‌است. این امر اطمینان بیشتری از آزمایش نتایج DL و ارزیابی جامع را فراهم می‌کند [۶۶].

جهت بررسی دقیق‌تر معماری‌ای که در نظر گرفتیم و بررسی پایداری نتایج آن ساختار شبکه را بدون تغییر پارامتری جز پارامتر حالت تصادفی<sup>۳۸</sup> بررسی نمودیم. برای این منظور صحت عملکرد شبکه با مقادیر مختلف ۱۲، ۲۴، ۴۲، ۶۴ و ۱۲۸ مورد

<sup>۳۸</sup> Random State

نتایج به دست آمده در این بخش نشان داد که علاوه بر موارد ذکر شده، استفاده از DL در راستای ارزیابی روش RFTSDP می‌تواند تفاوت استفاده از تحریک‌های مختلف را بهتر نشان دهد. در شکل (۹) نشان داده شده که در داده‌های انسانی با اعمال لرزش عملکرد CNN بهبود قابل توجهی نسبت به حالت ساده و استاتیک داشته و در تحریک‌های لرزشی در فرکانس‌های مختلف بهتر از SVM عمل کرده است. به عبارت دیگر علاوه بر پایداری نتایج با معماری استفاده شده به بهبود نتایج نیز دست یافتیم. بهترین نتایج نیز در هر دو رویکرد یادگیری ماشین و عمیق مربوط به فرکانس لرزشی ۶۵ هرتز می‌باشد که درصد صحت آن‌ها به ترتیب  $97/40 \pm 0/73$  و  $99/53 \pm 0/47$  بوده است.

مقایسه‌ی روش RFTSDP در طبقه‌بندی‌های مختلف ضایعه-ی پستان با استفاده از روش‌های مختلف طبقه‌بندی‌های یادگیری ماشین و مطالعات قبل از آن در [۲۴] انجام شده است. همچنین با نتایج ذکر شده در جدول (۲) که مرتبط به بررسی سری زمانی RF برای طبقه‌بندی و درجه‌بندی بافت پستان است، با استفاده از معماری ذکر شده در این مطالعه، ۲۶٫۸۶ درصد بهبود نسبت به نتایج تعیین نوع بافت چهار گروه گزارش شده در [۱۸] حاصل شد.


#### ۴-۴- بحث

نتایج نشان داد که درصد قابل توجهی بهبود دقت در طبقه‌بندی انواع ضایعه‌ها با اعمال تحریک لرزشی ایجاد شد. مطلوب‌ترین نتیجه با داده‌های UF BF در حالت ارتعاش در فرکانس ۶۵ هرتز حاصل شد. ارتعاش باعث جابجایی پراکنده‌های بافت، تغییر الگوهای پراکنندگی RF و بهبود نتایج بافت‌های مختلف شد. همچنین لازم به ذکر است برای مطالعه RF TS با اعمال لرزش، ترجیحاً داده‌ها با سرعت بالا نمونه‌برداری شوند تا امکان ردیابی بهتر تأثیر لرزش بر الگوهای بازگشتی و جابجایی پراکنده‌کننده‌ها فراهم شود. این رویکرد بینش بهتری در مورد پویایی محیط در طول لرزش بافت ارائه می‌دهد.


از آنجا که پدیده‌ی بازگشت سیگنال‌های RF بر پایه‌ی فرکانس است، تفسیر نتایج پردازش آن نیز به فرکانس بستگی دارد. فرکانس بهینه برای لرزش تحت تأثیر نوع بافت، شرایط ثبت، حالت تصویربرداری فراصوت، فرکانس مرکزی کاوش گر و غیره است. همان‌طور که نتایج نشان می‌دهد، طبقه‌بند در برخی از فرکانس‌های لرزش عملکرد ضعیف‌تری دارد. به این ترتیب بررسی فرکانس‌های مختلف و انتخاب بهترین نوع آن بر اساس بافت بسیار مهم است. همچنین در این پژوهش نیز تأیید شد که

### ۳-۴- مقایسه‌ی نتایج رویکردهای یادگیری ماشین و یادگیری عمیق

ملاحظه شد با تغییر مقادیر این پارامتر در بازه‌ی ۱۲ تا ۱۲۸ باز هم صحت عملکرد شبکه روی بهترین نوع تحریک نیز چندان تغییر نکرده است. بنابراین می‌توانیم به مقایسه‌ی این نتایج با عملکرد ML نیز بپردازیم. برای این منظور صحت طبقه‌بند SVM و CNN با روش‌های ارزیابی ذکر شده در بخش ۳-۳ در حالت‌های مختلف اعمال تحریک به صورت مجزا مقایسه شده است. مقادیر میانگین صحت برای پنج هسته‌ی SVM و CNN بعد از ۱۰ دوره‌ی کامل برای داده‌های BF UF محاسبه شد. این مقادیر برای داده‌های انسانی در شکل (۹) نشان داده شده است. میله‌های خطا نیز نشان‌دهنده‌ی انحراف استاندارد حاصل از تکرار طبقه‌بندی‌ها می‌باشد.



شکل (۸) - تغییرات صحت آزمایش شبکه برای داده‌های انسانی در لرزش ۶۵ هرتز با تغییر مقادیر پارامتر حالت تصادفی در بازه‌ی ۱۲ تا ۱۲۸.



شکل (۹) - مقایسه‌ی صحت دو رویکرد متفاوت DL و ML در طبقه‌بندی TS‌های ساخته شده از داده‌های بیم-فرم شده‌ی UF در انواع تحریک داده‌های انسانی Vib. 65Hz به معنای لرزش ۶۵ هرتز است.

همان‌طور که ذکر شد هر سری زمانی به عنوان یک ورودی مجزا برای شبکه و ۱۹ ویژگی طیفی و غیرخطی استخراج شده از آن به عنوان ورودی به ML داده شد.

مدل به دلیل انعطاف‌پذیری و تعمیم‌پذیری بیشتر در مواجهه شدن با داده‌هایی که قبلاً دیده نشده، استفاده شد. نتایج این مطالعه تایید کرد که اعمال لرزش، به ویژه در فرکانس خاص، در طبقه‌بندی بافت خارج شده‌ی پستان بسیار موثر است. این روش نه تنها در تمایز بین بافت سالم و بافت سرطانی، بلکه در تفکیک ضایعه‌های سرطانی و غیرسرطانی و حتی در درجه‌بندی ضایعه‌ی سرطانی نیز مفید است.

استفاده از RFTSDP در طبقه‌بندی پنج کلاسه و درجه‌بندی ضایعه‌ی IDC، بهبود دقت ۵/۶۸ درصدی را هنگام اعمال لرزش با فرکانس مناسب در مقایسه با حالت ساده در داده‌های BF UF ایجاد کرد. علاوه بر این، RFTSDP با استفاده از DL بهبود دقت ۲۶/۸۶ درصدی را نسبت به نتایج تعیین نوع بافت چهار گروه گزارش شده در [۱۸] نشان داد. در ادامه، هدف انجام مطالعات بالینی در مقیاس بزرگ با گروه‌های متنوع ضایعه‌های پستان، شامل انواع سرطانی و غیر سرطانی، است.

#### ۶- سپاس‌گزاری

نویسندگان مراتب قدردانی خود را از جناب آقای مهندس رضا رشیدزاده، مدیرعامل محترم شرکت تن‌آسا طب نوین، به پاس همکاری ایشان در جمع‌آوری داده‌ها، و همچنین از جناب آقای مهندس سعید عرب‌زاده (دانشکده مهندسی پزشکی، دانشگاه امیرکبیر، تهران، ایران)، به دلیل ارایه‌ی راهکارهای بسیار مفید در راستای طراحی شبکه، ابراز می‌دارند. همچنین، از جناب آقای دکتر کشوری (دانشکده مهندسی پزشکی، دانشگاه امیرکبیر، تهران، ایران)، سرکار خانم الف‌زاده (دانشکده فیزیک، دانشگاه امیرکبیر، تهران، ایران) و سرکار خانم شقایق صدیقی، بابت فراهم نمودن نمونه‌های بافت و ضایعه‌های برون‌تنی پستان، کمال تشکر را دارند.

#### ۷- مراجع

- Moradi, M., et al. *A new approach to analysis of RF ultrasound echo signals for tissue characterization: animal studies*. in *Medical Imaging 2007: Ultrasonic Imaging and Signal Processing*. 2007. SPIE.
- Wang, W., et al., *Strain estimation by a Fourier Series-based extrema tracking algorithm for elastography*. *Ultrasonics*, 2015. **62**: p. 278-291.
- منیژه، م.د.، طراحی و پیاده‌سازی دو نمونه سیستم بارگذار مکانیکی به منظور ایجاد استرس در بافت پستان.
- Lo, C., et al., *Computer-aided multiview tumor detection for automated whole breast ultrasound*. *Ultrasonic imaging*, 2014. **36**(1): p. 3-17.
- Moradi, M., P. Abolmaesumi, and P. Mousavi, *Tissue typing using ultrasound RF time series: experiments with animal tissue samples*. *Medical physics*, 2010. **37**(8): p. 4401-4413.

برای بررسی بافت پستان با فرکانس مرکزی ۶/۴ مگاهرتز بهترین فرکانس لرزش بافت، فرکانس ۶۵ هرتز می‌باشد.

در این مطالعه، با محدودیت‌هایی نیز مواجه شدیم که در این بخش مورد بحث قرار می‌گیرند. در روش پیشنهادی RFTSDP از همان تجهیزات فراصوت استفاده می‌شود که قادر به بررسی داده‌های خام فراصوت و نیز دارای حالت UF می‌باشد. استفاده از این حالت برای بهبود دنبال کردن حرکت پراکنده‌کننده‌ها ضروری است. علاوه بر این، یک لرزاننده‌ی خارجی طراحی و استفاده شد که در فاصله‌ی دو سانتی‌متر از کاوش‌گر قرار داشت. برای بررسی دقیق‌تر RFTSDP، باید لرزاننده‌ی دقیق‌تر طراحی شود تا فرکانس و نیروی مورد نظر را روی نمونه‌ی درون‌تنی تولید کند. گروه ارتجاع‌نگاری دانشکده مهندسی پزشکی در حال حاضر روی این موضوع کار می‌کند. در تحقیقات آینده در راستای RFTSDP، باید از لرزاننده‌ی استفاده‌شود که کمترین تأثیر را روی کاوش‌گر داشته‌باشد و امکان ثبت بالینی آسان را فراهم کند.

علاوه بر این، در روش‌های تحقیقاتی که مانند روش ما نیاز به یک محرک خارجی دارند، فرآیند تحقیق به این ترتیب دنبال می‌شود: ابتدا اثرات روش جدید و لرزاننده بر روی فانتوم‌ها، سپس بافت‌های حیوانی، بافت‌های خارج‌شده و در نهایت بافت‌های داخلی بررسی می‌شود. در این مقاله، از بافت‌های خارج‌شده درون فانتوم شبیه‌ساز بافت نرمال ثبت انجام شد. بررسی بافت خارج‌شده و همگن بودن فانتوم، دلایل اصلی تفاوت با ثبت‌های طبیعی هستند. در کارهای آینده برای تکمیل ارزیابی روش RFTSDP، باید از مدل لرزاننده‌ی بهبودیافته در محیط طبیعی بافت استفاده شود.

#### ۵- نتیجه‌گیری

سیگنال‌های بازگشتی RF اطلاعات ارزشمندی از محیط انتشار ارایه می‌دهند. با توجه به این که در روش‌های تعیین نوع بافت و تعیین مشخصات آن بسیار مفید بوده‌اند، ما پیشنهاد کردیم که ثبت سیگنال RF در حین اعمال تحریک انجام شود. با اضافه شدن پاسخ دینامیک و تغییرات پراکنده‌کننده‌ها، اطلاعات سیگنال غنی‌تر بوده و با پردازش این سیگنال و بررسی تغییرات الگوی بازگشتی، امکان تمایز ضایعه‌های مختلف پستان فراهم می‌شود. ما این روش را RFTSDP نامیدیم و در این مطالعه، عملکرد آن را روی بافت انسانی با استفاده از روش DL بررسی کردیم.

در این پژوهش از DL، به دلایل پایدارتر بودن نتایج این روش نسبت به ML به ویژه برای داده‌های بالینی و بهبود عملکرد



24. Ghehi, E.N., et al., *Evaluating the Effect of Tissue Stimulation at Different Frequencies on Breast Lesion Classification Based on Nonlinear Features Using a Novel Radio Frequency Time Series Approach*. Heliyon, 2024.
25. Gandomkar, Z., P.C. Brennan, and C. Mello-Thoms, *MuDeRN: Multi-category classification of breast histopathological image using deep residual networks*. Artificial intelligence in medicine, 2018. **88**: p. 14-24.
26. Han, Z., et al., *Breast cancer multi-classification from histopathological images with structured deep learning model*. Scientific reports, 2017. **7**(1): p. 4172.
27. Ahmad, N., S. Asghar, and S.A. Gillani, *Transfer learning-assisted multi-resolution breast cancer histopathological images classification*. The Visual Computer, 2022. **38**(8): p. 2751-2770.
28. Arefan, D., et al., *Deep learning modeling using normal mammograms for predicting breast cancer risk*. Medical physics, 2020. **47**(1): p. 110-118.
29. Kaur, P., *Predictive Detection of Breast Cancer with Artificial Neural Network and Support Vector Machine*. 2023.
30. Mridha, M.F., et al., *A comprehensive survey on deep-learning-based breast cancer diagnosis*. Cancers, 2021. **13**(23): p. 6116.
31. Khan, M.H.-M. *Automated breast cancer diagnosis using artificial neural network (ANN)*. in *2017 3rd Iranian Conference on Intelligent Systems and Signal Processing (ICSPIS)*. 2017. IEEE.
32. Carneiro, G., J. Nascimento, and A.P. Bradley, *Automated analysis of unregistered multi-view mammograms with deep learning*. IEEE transactions on medical imaging, 2017. **36**(11): p. 2355-2365.
33. Painuli, D. and S. Bhardwaj, *Recent advancement in cancer diagnosis using machine learning and deep learning techniques: A comprehensive review*. Computers in Biology and Medicine, 2022. **146**: p. 105580.
34. Han, S., et al., *A deep learning framework for supporting the classification of breast lesions in ultrasound images*. Physics in Medicine & Biology, 2017. **62**(19): p. 7714.
35. Duraisamy, S. and S. Emperumal, *Computer-aided mammogram diagnosis system using deep learning convolutional fully complex-valued relaxation neural network classifier*. IET Computer Vision, 2017. **11**(8): p. 656-662.
36. Zhou, L.-Q., et al., *Lymph node metastasis prediction from primary breast cancer US images using deep learning*. Radiology, 2020. **294**(1): p. 19-28.
37. Ru, J., Z. Zhu, and J. Shi, *Spatial and geometric learning for classification of breast tumors from multi-center ultrasound images: a hybrid learning approach*. BMC Medical Imaging, 2024. **24**.
38. Jarosik, P., et al., *Breast lesion classification based on ultrasonic radio-frequency signals using convolutional neural networks*. Biocybernetics and Biomedical Engineering, 2020. **40**(3): p. 977-986.
39. Qiao, M., et al., *Breast calcification detection based on multichannel radiofrequency signals via a unified deep learning framework*. Expert Systems with Applications, 2021. **168**: p. 114218.
40. Pang, T., et al., *Semi-supervised GAN-based radiomics model for data augmentation in breast ultrasound mass classification*. Computer Methods and Programs in Biomedicine, 2021. **203**: p. 106018.
41. Bakheet, D. and K. Maharatna, *Linear and nonlinear analysis of intrinsic mode function after facial stimuli presentation in children with autism spectrum disorder*. 6. Moradi, M., et al. *Ultrasound RF time series for tissue typing: first in vivo clinical results*. in *Medical Imaging 2013: Computer-Aided Diagnosis*. 2013. SPIE.
7. Dar, R.A., M. Rasool, and A. Assad, *Breast cancer detection using deep learning: Datasets, methods, and challenges ahead*. Computers in biology and medicine, 2022. **149**: p. 106073.
8. Moradi, M., et al. *Detection of prostate cancer from RF ultrasound echo signals using fractal analysis*. in *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*. 2006. IEEE.
9. Mohammad, A., et al. *Automated detection of prostate cancer using wavelet transform features of ultrasound RF time series*. in *Proc. SPIE*. 2009.
10. Moradi, M., et al., *Augmenting detection of prostate cancer in transrectal ultrasound images using SVM and RF time series*. IEEE Transactions on Biomedical Engineering, 2008. **56**(9): p. 2214-2224.
11. Uniyal, N., et al., *Ultrasound RF time series for classification of breast lesions*. IEEE transactions on medical imaging, 2014. **34**(2): p. 652-661.
12. Aboofazeli, M., et al. *Automated detection of prostate cancer using wavelet transform features of ultrasound RF time series*. in *Medical Imaging 2009: Computer-Aided Diagnosis*. 2009. SPIE.
13. Imani, F., et al. *Ultrasound-based characterization of prostate cancer: an in vivo clinical feasibility study*. in *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2013: 16th International Conference, Nagoya, Japan, September 22-26, 2013, Proceedings, Part II* 16. 2013. Springer.
14. Imani, F., et al., *Computer-aided prostate cancer detection using ultrasound RF time series: in vivo feasibility study*. IEEE transactions on medical imaging, 2015. **34**(11): p. 2248-2257.
15. Khojaste, A., et al. *Characterization of aggressive prostate cancer using ultrasound RF time series*. in *Medical Imaging 2015: Computer-Aided Diagnosis*. 2015. SPIE.
16. Moradi, M., et al. *Tissue typing with ultrasound RF time series: phantom studies*. in *Medical Imaging 2009: Ultrasonic Imaging and Signal Processing*. 2009. SPIE.
17. Moradi, M., et al. *P6C-7 ultrasound RF time series for detection of prostate cancer: feature selection and frame rate analysis*. in *2007 IEEE Ultrasonics Symposium Proceedings*. 2007. IEEE.
18. Uniyal, N., *Ultrasound-based approaches to tissue classification for breast and prostate cancer diagnosis*. 2014, University of British Columbia.
19. Godavarty, A., et al., *Optical imaging for breast cancer prescreening*. Breast Cancer: Targets and Therapy, 2015: p. 193-209.
20. Risbridger, G.P., et al., *Breast and prostate cancer: more similar than different*. Nature Reviews Cancer, 2010. **10**(3): p. 205-212.
21. Gennisson, J.-L., et al., *Assessment of elastic parameters of human skin using dynamic elastography*. IEEE transactions on ultrasonics, ferroelectrics, and frequency control, 2004. **51**(8): p. 980-989.
22. Ghehi, E.N., et al. *Effect of Tissue excitation in breast cancer detection from ultrasound RF time series: Phantom studies*. in *2021 11th International Conference on Computer Engineering and Knowledge (ICCKE)*. 2021. IEEE.
23. Ghehi, E.N., et al. *Breast cancer detection from a new ultrasound RF time series based approach: Phantom studies*. in *2021 28th National and 6th International Iranian Conference on Biomedical Engineering (ICBME)*. 2021. IEEE.



58. Szandata, T., *Review and comparison of commonly used activation functions for deep neural networks*, in *Bio-inspired neurocomputing*. 2020, Springer. p. 203-224.
59. Yao, J., et al., *Machine Learning-Based Sizing Model for Tapered Electrical Submersible Pumps Under Multiple Operating Conditions*. *Processes*, 2025. **13**(4): p. 1056.
60. Zafar, A., et al., *A comparison of pooling methods for convolutional neural networks*. *Applied Sciences*, 2022. **12**(17): p. 8643.
61. Trivedi, S.K., et al., *Prediction of consumers refill frequency of LPG: A study using explainable machine learning*. *Heliyon*, 2024. **10**(1).
62. Zhang, B., S. Hu, and M. Li, *Comparative study of multiple machine learning algorithms for risk level prediction in goaf*. *Heliyon*, 2023. **9**(8).
63. Grandini, M., E. Bagli, and G. Visani, *Metrics for multi-class classification: an overview*. arXiv preprint arXiv:2008.05756, 2020.
64. Chicco, D. and G. Jurman, *The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation*. *BMC genomics*, 2020. **21**: p. 1-13.
65. Foody, G.M., *Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient*. *Plos one*, 2023. **18**(10): p. e0291908.
66. Bisht, R.K. and I.P. Bisht. *Investigation of the Role of Test Size, Random State, and Dataset in the Accuracy of Classification Algorithms*. in *International Conference on Communication and Intelligent Systems*. 2022. Springer.
- Computers in Biology and Medicine, 2021. **133**: p. 104376.
42. Saghaei Noosh Abadi, Z., A. Aghajani, and M. Haghpanahi, *Domestic Construction of Soft Tissue Phantom for Validation Linear Quasi-Static Elastography*. *Iranian Journal of Biomedical Engineering*, 2013. **7**(1): p. 1-11.
43. Kavitha, M. and M.R. Reddy. *Characterization of tissue mimicking phantoms for acoustic radiation force impulse imaging*. in *2012 IEEE International Conference on Imaging Systems and Techniques Proceedings*. 2012. IEEE.
44. Xia, W., et al., *Poly (vinyl alcohol) gels as photoacoustic breast phantoms revisited*. *Journal of biomedical optics*, 2011. **16**(7): p. 075002-075002-10.
45. Faruk, T., et al., *The journey of elastography: background, current status, and future possibilities in breast cancer diagnosis*. *Clinical breast cancer*, 2015. **15**(5): p. 313-324.
46. Mahdavi, S.S., et al., *Evaluation of visualization of the prostate gland in vibro-elastography images*. *Medical image analysis*, 2011. **15**(4): p. 589-600.
47. Varghese, T., *Quasi-static ultrasound elastography*. *Ultrasound clinics*, 2009. **4**(3): p. 323.
48. Krouskop, T.A., et al., *Elastic moduli of breast and prostate tissues under compression*. *Ultrasonic imaging*, 1998. **20**(4): p. 260-274.
49. Li, G.-Y. and Y. Cao, *Mechanics of ultrasound elastography*. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2017. **473**(2199): p. 20160841.
50. Zahiri-Azar, R. and S.E. Salcudean, *Motion estimation in ultrasound images using time domain cross correlation with prior estimates*. *IEEE Transactions on Biomedical Engineering*, 2006. **53**(10): p. 1990-2000.
51. Rivaz, H. and R. Rohling. *A hand-held probe for vibro-elastography*. in *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2005: 8th International Conference, Palm Springs, CA, USA, October 26-29, 2005, Proceedings, Part I 8*. 2005. Springer.
52. Mehrabian, H., G. Campbell, and A. Samani, *A constrained reconstruction technique of hyperelasticity parameters for breast cancer assessment*. *Physics in Medicine & Biology*, 2010. **55**(24): p. 7489.
53. Kharine, A., et al., *Poly (vinyl alcohol) gels for use as tissue phantoms in photoacoustic mammography*. *Physics in Medicine & Biology*, 2003. **48**(3): p. 357.
54. Devi, C.U., R.M. Vasu, and A. Sood, *Design, fabrication, and characterization of a tissue-equivalent phantom for optical elastography*. *Journal of biomedical optics*, 2005. **10**(4): p. 044020-044020-10.
55. Fromageau, J., et al., *Estimation of polyvinyl alcohol cryogel mechanical properties with four ultrasound elastography methods and comparison with gold standard testings*. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 2007. **54**(3): p. 498-509.
56. Mousavi, S.R., et al., *Breast ultrasound elastography using full inversion-based elastic modulus reconstruction*. *IEEE Transactions on Computational Imaging*, 2017. **3**(4): p. 774-782.
57. Jabeen, K., et al., *Breast cancer classification from ultrasound images using probability-based optimal deep learning feature fusion*. *Sensors*, 2022. **22**(3): p. 807.