

Enhancing HIFU Lesion Area Detection through Supervised and Contrastive Self-Supervised Learning with Wavelet-Based Feature Extraction and Hard Negatives (HWCSSL)

Matineh Zavar¹, Hamid Reza Ghaffari^{1*}, Hamid Tabatabaee^{2,3}

1. Department of Computer Engineering, Ferdows Branch, Islamic Azad University, Ferdows, Iran.

2. Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran.

3. Department of Artificial Intelligent and Data Science, Intelligent Financial Innovation Research Center, Mashhad Branch, Islamic Azad University, Mashhad, Iran.

ARTICLE INFO:

Article History:

Received: 2 Nov 2024

Accepted: 18 Feb 2025

Published: 18 Mar 2025

*Corresponding

Author: Hamid Reza Ghaffari

Email:

hghaffari_papers@ferdowsiau.ac.ir

Citation: Zavar M, Ghaffari HR, Tabatabaee H. Enhancing HIFU Lesion Area Detection through Supervised and Contrastive Self-Supervised Learning with Wavelet-Based Feature Extraction and Hard Negatives (HWCSSL). Journal of Health and Biomedical Informatics 2025; 11(4): 336-47. [In Persian]

Abstract

Introduction: Artificial intelligence (AI) has brought about transformative changes across multiple domains including classification, detection, and prediction through the implementation of sophisticated machine learning algorithms, with the ultimate objective of enhancing quality of life and service delivery. Conventional approaches that rely on manually engineered features encounter significant limitations when applied to complex tasks such as medical diagnosis, particularly in terms of suboptimal feature extraction capabilities and heightened sensitivity to noise interference. The emergence of deep neural networks, with their inherent capacity for automated feature extraction, has revolutionized contemporary data analysis methodologies. The current study leverages this technological advancement for the detection of lesions generated by High-Intensity Focused Ultrasound (HIFU), an innovative therapeutic technique developed for oncological treatment and hemorrhage management. The proposed methodology integrates both supervised and self-supervised learning paradigms to enhance detection accuracy by effectively utilizing both labeled and unlabeled clinical datasets.

Method: A key challenge in traditional methods lies in optimal feature extraction and hyperparameter tuning. This research develops an innovative framework integrating supervised and contrastive self-supervised learning. The model processes both RF signals and B-mode images as inputs, simultaneously handling labeled and unlabeled data. Data augmentation techniques, including wavelet transforms and hard negative sampling were employed. Model optimization was achieved through advanced algorithms and fine-tuned hyperparameters to enhance performance in complex scenarios. This approach enabled concurrent analysis of multimodal data, improving diagnostic accuracy.

Results: The proposed model demonstrated substantial improvements in HIFU-induced lesion classification performance. Quantitative evaluation metrics, including accuracy, precision, recall, and F1-score, consistently validated the model's efficacy in discriminating between healthy and pathological tissue regions. The multimodal integration of signal processing and image analysis components yielded remarkable enhancements in overall system performance. The incorporation of self-supervised learning algorithms coupled with wavelet transform techniques substantially augmented the model's feature extraction capabilities, resulting in superior diagnostic accuracy compared to conventional approaches.

Conclusion: This investigation presents a robust and precise framework for HIFU lesion detection that effectively employs self-supervised learning methodologies. The developed system successfully extracts clinically relevant information from unlabeled datasets while achieving significant improvements in diagnostic reliability. By addressing critical challenges in medical imaging applications, particularly in non-invasive therapeutic interventions, this approach demonstrates considerable potential for enhancing clinical workflows. The proposed methodology establishes a foundational platform for the future development of advanced diagnostic tools in therapeutic ultrasound applications.

Keywords: High-Intensity Focused Ultrasound, Deep Neural Networks, Self-Supervised Learning, Lesion Detection, Contrastive Learning, Wavelet Transform



CrossMark

مقاله پژوهشی

بهبود تشخیص ناحیه جراحی HIFU از طریق یادگیری نظارت شده و خودنظارتی متضاد با استخراج ویژگی مبتنی بر موجک و نمونه‌های منفی سخت (HWCSSL)

متینه زوار^۱، حمیدرضا غفاری^{۱*}، حمید طباطبایی^{۲،۳}

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

۲. گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.

۳. گروه هوش مصنوعی و علم داده، مرکز تحقیقات نوآوری های مالی هوشمند، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۳/۸/۱۲

پذیرش: ۱۴۰۳/۱۱/۳۰

انتشار برخط: ۱۴۰۳/۱۲/۲۸

*نویسنده مسئول:

حمیدرضا غفاری

ایمیل:

hghaffari_papers@ferdo.wsiau.ac.ir

ارجاع: زوار متینه، غفاری

حمیدرضا، طباطبایی حمید. بهبود

تشخیص ناحیه جراحی HIFU

از طریق یادگیری نظارت شده و

خودنظارتی متضاد با استخراج

ویژگی مبتنی بر موجک و

نمونه‌های منفی سخت

(HWCSSL).

مجله

انفورماتیک سلامت و زیست

پزشکی ۱۴۰۳؛ ۱۱(۴): ۳۳۶-۳۴۷.

مقدمه: هوش مصنوعی با بهره‌گیری از الگوریتم‌های یادگیری ماشین، حوزه‌های مختلف از جمله طبقه‌بندی، تشخیص و پیش‌بینی را متحول کرده است که هدف آن ارتقای کیفیت زندگی و خدمات می‌باشد. روش‌های سنتی مبتنی بر ویژگی‌های دستی، در وظایف پیچیده مانند تشخیص پزشکی با محدودیت‌هایی مواجه هستند، از جمله ناتوانی در استخراج بهینه ویژگی‌ها و حساسیت به نویز. پیشرفت شبکه‌های عصبی عمیق با توانایی استخراج خودکار ویژگی‌ها، تحلیل داده‌ها را متحول کرده است. این مطالعه از این قابلیت برای تشخیص جراحی ناشی از اولتراسوند متمرکز با شدت بالا (HIFU) استفاده می‌کند، تکنیکی که برای درمان سرطان و کنترل خونریزی توسعه یافته است. رویکرد پیشنهادی مبتنی بر یادگیری نظارت شده و خودنظارتی است که با استفاده از داده‌های برچسب‌دار و بدون برچسب، دقت تشخیص را بهبود می‌بخشد.

روش کار: چالش اصلی روش‌های سنتی، استخراج بهینه ویژگی‌ها و بهینه‌سازی فرایارامترهاست. در این پژوهش، روشی نوآورانه با ترکیب یادگیری نظارت شده، خودنظارتی متضاد توسعه داده شد. این روش از سیگنال‌های RF و تصاویر B-mode به عنوان ورودی استفاده می‌کند و داده‌های برچسب‌دار و بدون برچسب را به صورت همزمان پردازش می‌کند. همچنین، تکنیک‌های افزایش داده مانند تبدیل‌های موجک و نمونه‌های منفی سخت به کار گرفته شدند و بهینه‌سازی مدل با استفاده از الگوریتم‌های پیشرفته و تنظیم دقیق فرایارامترها انجام شد تا عملکرد مدل در شرایط پیچیده تقویت شود. این رویکرد امکان تحلیل هم‌زمان داده‌های چندگانه را فراهم کرد و به افزایش دقت تشخیصی کمک نمود.

یافته‌ها: مدل پیشنهادی بهبود قابل توجهی در طبقه‌بندی جراحی HIFU نشان داد. معیارهای ارزیابی شامل دقت، صحت، یادآوری و امتیاز F1، کارایی مدل در تمایز بین بافت‌های سالم و آسیب‌دیده را تأیید کردند. ترکیب سیگنال و تصویر به بهبود چشمگیر عملکرد مدل منجر شد. استفاده از یادگیری خودنظارتی و تبدیل‌های موجک، توانایی مدل در استخراج ویژگی‌ها، را تقویت کرد و دقت تشخیصی را افزایش داد.

نتیجه‌گیری: این مطالعه چارچوبی دقیق برای تشخیص جراحی HIFU با استفاده از یادگیری خودنظارتی ارائه کرد که امکان استخراج اطلاعات ارزشمند از داده‌های بدون برچسب را فراهم نمود و دقت تشخیصی را به طور قابل توجهی بهبود بخشید. این روش با غلبه بر چالش‌های تصویربرداری پزشکی، به ویژه در درمان‌های غیرتهاجمی، کاربردهای بالینی را تقویت می‌کند که می‌تواند به عنوان پایه‌ای برای توسعه ابزارهای تشخیصی پیشرفته‌تر در آینده عمل کند.

کلیدواژه‌ها: اولتراسوند متمرکز با شدت بالا، شبکه‌های عصبی عمیق، یادگیری خودنظارتی، تشخیص جراحی، یادگیری متضاد، تبدیل موجک

مقدمه

مدل‌های مبتنی بر شبکه‌های عصبی عمیق (Deep Neural Networks) در تحلیل تصاویر پزشکی، به ویژه در تشخیص و شناسایی بیماری‌ها، به موفقیت‌های قابل توجهی دست یافته‌اند. در زمینه پزشکی، جراحی‌های غیرتهاجمی مانند اولتراسوند متمرکز با شدت بالا یا HIFU (High Intensity Focused Ultrasound)، با استفاده از امواج متمرکز اولتراسوند برای درمان انواع تومورها و بیماری‌ها، بدون آسیب به بافت‌های میانی مرسوم شده است. یکی از چالش‌های درمان HIFU، طبقه‌بندی دقیق ناحیه جراحی است. به همین دلیل، استراتژی‌هایی مبتنی بر تحلیل سیگنال یا تصاویر اولتراسوند B-mode برای پایش HIFU مورد استفاده قرار گرفته‌اند [۱]. سیگنال و تصاویر اولتراسوند مربوط به ناحیه جراحی باید به گونه‌ای هوشمندانه تحلیل شوند تا بافت‌های سالم از ناحیه جراحی تفکیک شده و از آسیب به بافت‌های سالم طی فرآیند گرمایش جلوگیری شود. کارایی یادگیری عمیق در زمینه‌هایی تشخیص اشیاء [۳]، طبقه‌بندی [۵، ۶] و تقسیم‌بندی [۷، ۸] اغلب به یادگیری نظارت‌شده و حجم زیادی از داده‌های برچسب‌دار نیاز دارد؛ بنابراین به دلیل هزینه‌های زیاد و محدودیت‌های مربوط به محرمانگی داده‌ها، روش‌های یادگیری جایگزین مانند یادگیری خودنظارتی توسعه یافته‌اند [۹، ۱۰]. یادگیری متضاد و شبکه‌های مولد تخصصی یا GAN (Generative Adversarial Network) نمونه‌ای از روش‌هایی بدون نظارت، نیمه‌نظارت‌شده و خودنظارتی هستند که در طبقه‌بندی یا بخش‌بندی و در تولید تصاویر یا اشیاء سه‌بعدی استفاده شوند. این تنوع در روش‌ها و کاربردها نشان‌دهنده توانایی‌های گسترده یادگیری ماشین است که انعطاف‌پذیری و کارایی بالایی برای رفع نیازهای مختلف ارائه می‌دهد [۱۱-۱۳]. این نوع یادگیری، شبکه‌ها را قادر می‌سازد تا ویژگی‌های پیچیده تصاویر را بدون نیاز به برچسب‌های صریح یاد بگیرند.


چالش‌هایی از جمله تعداد کم نمونه‌ها، عدم وجود برچسب‌ها برای برخی داده‌ها و زمان‌بر بودن آموزش نظارت‌شده عمیق، منجر به این پژوهش شد تا از روش یادگیری خودنظارتی بهره گرفته شود. این روش به‌طور همزمان داده‌های برچسب‌دار و بدون برچسب را پردازش کرده و منجر به بهبود پایش HIFU می‌شود که الگوهای نواحی جراحی با ترکیب یادگیری نظارت‌شده و خودنظارتی آموخته شده است. کاربرد یادگیری عمیق در پردازش تصاویر پزشکی در مقالات متعددی به‌طور گسترده مورد بحث قرار گرفته است [۱۴-۱۶]. با این حال، چالش‌های منحصر به فرد پردازش تصاویر پزشکی به ویژه محدودیت داده‌ها و برچسب‌گذاری آن‌ها، بر کاهش وابستگی به برچسب‌گذاری داده‌ها در انواع مختلف تصاویر پزشکی متمرکز بوده است [۱۷-۱۹]. مطالعات عمدتاً بر روی روش‌های خودنظارتی برای تصاویر اشعه ایکس ام‌آر‌آی و سی‌تی اسکن تمرکز داشته‌اند [۱۰، ۲۰، ۲۱] و تعداد کمی به تصاویر اولتراسوند، به‌ویژه به کنترل و پایش HIFU پرداخته‌اند. پژوهشی با استفاده از سیگنال‌های اولتراسوند به عنوان ورودی به یک شبکه عصبی پیش‌خور برای تشخیص ناحیه جراحی معرفی می‌کنند و مطالعه دیگری یک شبکه عصبی حافظه طولانی کوتاه مدت یا LSTM (Long Short Term Memory) را برای پایش تغییرات دمای ناشی از HIFU از طریق سیگنال‌های اولتراسوند پیشنهاد کرده است [۲۲-۲۴].

این مطالعه و بررسی این پژوهش‌ها به یک مشاهده مهم اشاره دارد: اخیراً تحقیقات کمی به‌طور خاص بر طبقه‌بندی تصاویر پزشکی اولتراسوند با استفاده از شبکه‌های عمیق خودنظارتی و آن‌هم با هدف تشخیص و آشکارسازی، تمرکز داشته‌اند. لذا در بخش روش کار به طور کامل با بررسی داده‌ها، الگوریتم پیشنهادی در قالب نمودار آمده، سپس ساخت روش جدید خودنظارتی، نوآوری در فاز استخراج ویژگی تشریح شده است. در بخش نتایج ضمن معرفی معیارهای ارزیابی، روش خودنظارتی MoCo، SimCLR و روش نوآورانه ی تشریح شده با عنوان HWCSSL با پارامترها و فرآیندهای مختلف در قالب جدول مورد مقایسه قرار گرفته‌اند.

روش کار

برای ارزیابی روش خودنظارتی، از داده‌های آزمایشگاه اولتراسوند دانشگاه رایسون کانادا استفاده شد که طی درمان‌های HIFU in vitro روی بافت عضلانی خوک جمع‌آوری شده بود که در مجموع ۷۶ فریم ثبت شده است و هر فریم شامل ۷۰ خط و هر خط از ۴۶۸۰ نمونه تشکیل شده است [۲۵]. روش پیشنهادی برای طبقه‌بندی نواحی جراحی با HIFU با استفاده از تصاویر اولتراسوند و سی‌تی‌اسکن ارزیابی شد. مجموعه داده‌های "ImageNet"، "مجموعه داده‌های اولتراسوند پستان" و "DeepLesion" که به ترتیب

برای طبقه‌بندی تصاویر عمومی، بررسی جراحات‌های پستان و تشخیص جراحات در اندام‌ها و بخش‌های مختلف بدن استفاده می‌شوند و هر یک شامل داده‌های متنوع و با برچسب‌گذاری‌های مختلف است و در فرآیند پیش‌آموزش شرکت داده شده‌اند. ماهیت داده‌های اولتراسوند در سیگنال RF نهفته است که به منظور تسهیل درک برای انسان، به تصویر بازسازی می‌شود. در بسیاری از مقالات متمرکز بر داده‌های اولتراسوند، تأکید بر مطالعه سیگنال RF است؛ زیرا این سیگنال ساختار آکوستیک بافت را دقیق‌تر نشان می‌دهد. با این حال، باید توجه داشت که در فرآیند تبدیل سیگنال به تصویر، برخی از ویژگی‌های مهم و ناشناخته که برای تشخیص دقیق ضروری هستند، ممکن است از دست بروند. از طرف دیگر، تحلیل تصویر برای پزشکان یا اپراتورهای مربوطه آسان‌تر از تحلیل سیگنال است، بنابراین استفاده از ویژگی‌های استخراج شده از سیگنال RF به دلیل وجود ویژگی‌های مهم در سیگنال بازگشتی، چه قبل و چه بعد از درمان HIFU، توصیه می‌شود. علاوه بر این، ویژگی‌هایی از تصاویر B-mode بر اساس دانش به دست آمده از مجموعه داده‌های بزرگ و بدون برچسب استخراج می‌شود. در نهایت، طبقه‌بند از یک بردار ترکیبی از ویژگی‌های سیگنال و تصویر برای شناسایی ناحیه جراحات استفاده می‌کند شکل ۱ نموداری را نشان می‌دهد که روش پیشنهادی را به صورت کلی از دو مرحله (از بارگذاری داده و پیش‌پردازش تا ساخت مدل، استخراج ویژگی‌ها و وظایف طبقه‌بندی) توضیح می‌دهد.



شکل ۱: ساختار کلی روش پیشنهادی


فاز اول (نارنجی رنگ) مربوط به پیش‌آموزش با روش یادگیری خودنظارتی متضاد مبتنی بر شبکه ResNet و لایه ادغام موجک است و فاز دوم (آبی رنگ) استخراج ویژگی و دسته‌بندی براساس مدل پیش آموزش دیده

فاز اول: ساخت روش جدید خودنظارتی

هر الگوریتم خودنظارتی با توجه به کارایی خود دارای بخش‌های مهمی از جمله بخش داده‌افزایی (Data Augmentation) کدگذار (Encoder)، بخش فراقنی غیرخطی (Nonlinear Projection Head)، معیار شباهت (similarity measure) و تابع ضرر (Loss Function) که نوآوری این پژوهش، تغییرات عمده همه این بخش‌ها را شامل می‌شود و این اصلاحات با هدف افزایش کارایی در تشخیص نواحی جراحات انجام شده‌اند که به شرح زیر می‌باشند: شکل ۲ شماتیکی از عبور هر سه مجموعه داده بزرگ بدون برچسب ذکر شده را از طریق ساختار داده خودناظر متضاد ResNet50 نشان می‌دهد. ساختار معماری اصلاح‌شده به شرح زیر است:

- پیش‌پردازش تصویر: شامل تغییر اندازه تصاویر و نرمال‌سازی داده‌ها است که خصوصاً برای مجموعه داده Deep Lesion به دلیل اندازه‌های مختلف تصاویر، بسیار حیاتی است.
- تعیین اندازه دسته (Batch size) (به عنوان درصدی از مجموعه داده کامل)
- انتخاب دو روش داده‌افزایی تصادفی (طبق جدول ۲) برای دسته تصویر مرجع (لنگر) (Anchor).
- وارد کردن تصاویر به ResNet، جایی که یک تصویر به عنوان مرجع انتخاب و با دیگر تصاویر مقایسه می‌شود:
 - در ابتدا، تصاویر از طریق ۶۴ فیلتر کانولوشن دو بعدی در ۷ در ۷ پردازش می‌شوند.
 - داده‌ها از لایه ادغام موجک (Wavelet pooling) عبور می‌کنند.
 - عبور از سه بلوک باقیمانده که شامل ۶۴ بلوک با اندازه‌های ۱ در ۱، ۳ در ۳، و ۱ در ۱ هستند.


- پس از بلوک‌های عادی و بلوک‌های کانولوشن باقیمانده، داده‌ها از یک مرحله دیگر لایه ادغام موجک عبور می‌کنند. در نهایت پس از ساخت معماری، می‌توان دانش به دست آمده از این ساختار را به مجموعه داده دیگری انتقال داد.



شکل ۲: پیش آموزش داده‌های بدون برجسب توسط ساختار پیشنهادی خودنظارتی- معماری اصلاح شده ResNet

❖ تبدیل موجک

تصاویر به‌عنوان آرایه‌های دوبعدی، ترکیبی از لبه‌ها و نواحی همگن با شدت‌های متفاوت هستند. موجک برای تحلیل چندرزولوشنی استفاده می‌شود، که امکان نمایش ویژگی‌ها در مقیاس‌های مختلف را فراهم می‌کند و کمک می‌کند تا برخی جزئیات که در یک رزولوشن دیده نمی‌شوند، در رزولوشن دیگر ظاهر شوند. تصویر برای استخراج ویژگی به دو زیرباند فرکانس پایین و فرکانس بالا تقسیم می‌شود. تحلیل تبدیل موجک گسسته چهار زیرباند تولید می‌کند که یکی نمایانگر تقریب (فرکانس پایین) و سه تای دیگر شامل جزئیات فرکانس بالا (افقی، عمودی، و مورب) هستند. توابع موجک کاربردهای متنوعی مانند استخراج ویژگی و حذف نویز دارند [۲۶]. در این پژوهش، استفاده از موجک به‌عنوان جایگزینی برای لایه ادغام در معماری کدگذار ResNet و برای داده‌افزایی بررسی شده است. ساختار استخراج‌کننده در یادگیری عمیق نقش مهمی در بهبود نمایش و عملکرد دارد. لایه ادغام معمولاً برای کاهش ابعاد تصویر و مدیریت بیش‌برازش استفاده می‌شود، اما روش‌های ادغام بیشینه (Max pooling) و ادغام میانگین (Avg pooling) ممکن است باعث از دست رفتن اطلاعات مهم شوند. برای کاهش این مشکل، از تبدیل موجک برای کاهش ابعاد بردار ویژگی استفاده می‌شود تا حداقل اطلاعات از دست برود؛ لذا از ترکیبی از توابع مادر ویولت استفاده می‌شود و در طول آموزش به‌طور تصادفی یکی انتخاب می‌گردد. پس از انتخاب یک تابع مادر ویولت خاص، فرآیند به دو سطح تجزیه ادامه می‌یابد. شکل ۳ نتایج این تحلیل را روی تصویر جراحی نشان می‌دهد.



شکل ۳: ضرایب موجک برای سه تابع موجک روی یک تصویر



❖ داده‌افزایی

در مجموعه داده‌های پزشکی، روش‌های معمول داده‌افزایی مانند برش تصویر، تغییر شدت نور، تغییر رنگ، یا تنظیم تصادفی به طیف خاکستری ممکن است به دلیل محدودیت‌های مجموعه داده قابل اجرا نباشند؛ بنابراین رویکردی نوآورانه شامل سفارشی‌سازی داده‌افزایی است که با انتخاب تصادفی و مناسب‌ترین روش‌ها برای هر مجموعه داده انجام می‌شود؛ بنابراین به‌جای استفاده از تارگی، برش تصادفی می‌توان از تکنیک جابه‌جایی عمودی و افقی تصویر، وارونه‌سازی، چرخش تصویر و ضرایب موجک بهره جست.

❖ تابع ضرر

در تحلیل تابع ضرر در روش یادگیری متضاد، هدف اصلی تقریب سطوح شباهت است. تابع NCE اغلب به برآورد شباهت برای ورودی‌های گسترده مانند مدل‌سازی زبان بسیار مفید است. با افزایش اندازه دسته، NCE به InfoNCE تبدیل می‌شود، تابع InfoNCE برای حفظ اطلاعات متقابل بین تصاویر کاربرد دارد. نسخه‌های مختلفی از این تابع مانند NT-Xent و MoCo برای تقویت شباهت و تفاوت تصاویر به کار می‌روند و از شباهت کسینوسی برای محاسبه استفاده می‌کنند. در این پژوهش، تلاش شده تصاویری که در فضای پنهان به اشتباه از نقطه اصلی دور شده‌اند با امتیازات شباهت تصحیح شوند. روش‌های سنتی معمولاً از توزیع گوسی برای ارزیابی شباهت استفاده می‌کنند، اما در این روش، تابع شباهت مبتنی بر توزیع کای (توزیع t با یک درجه آزادی) در نظر گرفته شده است. تشخیص منفی‌های کاذب، به‌ویژه در روش‌های بدون برچسب، چالش‌برانگیز است؛ اما شناسایی آن‌ها برای افزودن به مجموعه داده به‌عنوان منفی‌های دشوار، اهمیت دارد. برای رفع این موضوع، یک استراتژی شامل محدوددهای از پارامتر آستانه مورد بررسی قرار گرفت. (الگوریتم پیشنهادی در جدول ۱) زمانی که درجه شباهت در این محدوده قرار گیرد، شباهت با دورترین داده نسبت به نقطه مرجع (داده منفی) محاسبه می‌شود. مقایسه این دو درجه شباهت-یکی با نقطه مرجع و دیگری با داده منفی- تعیین می‌کند که داده مثبت است یا منفی. اگر شباهت به نقطه مرجع بیشتر باشد، داده جذب می‌شود؛ برعکس، اگر امتیاز عدم شباهت از شباهت بیشتر باشد، داده از نقطه مرجع دور می‌شود در روند الگوریتم پیشنهادی برای هد فراقنی غیر خطی از یک شبکه پرسپترون چندلایه یا MLP (Multi-Layer Perceptron) با دو لایه مخفی، به‌همراه یک لایه نرمال‌سازی دسته‌ای پیش از لایه اولیه استفاده شده است. تابع شباهت کسینوسی برای تعیین درجه شباهت بر اساس زاویه بین دو بردار استفاده می‌شود. امتیاز $\cdot$ نشان‌دهنده عدم شباهت (عمود بودن) است، در حالی که امتیاز ۱ نشان‌دهنده شباهت است. داده‌های مثبت، پس از تعیین شباهت‌شان، به سمت نقطه مرجع جذب می‌شوند. هرگاه داده منفی شناسایی شود، مقدار شباهت آن با مقدار حداقل شباهت فعلی (minNeg) ارزیابی شده و به‌روزرسانی می‌شود. (این مقدار همواره دورترین داده منفی از نقطه مرجع را نگه می‌دارد). اگر مقدار شباهت داده در محدوده آستانه ($T1$, $T2$) که معمولاً بین ۰/۴ تا ۰/۶ است، قرار گیرد، شباهت داده با minNeg ارزیابی می‌شود. با استفاده از درجه شباهت به نقطه مرجع و دورترین داده منفی، تصمیم‌گیری می‌شود که داده جدید به نقطه مرجع نزدیک‌تر شود یا از آن دورتر گردد.

جدول ۱: الگوریتم پیشنهادی برای تابع ضرر متضاد- اصلاح تابع کسینوسی با در نظر گرفتن منفی‌های سخت

```

Input: Threshold  $T1$ ,  $T2$  *  $TP = \text{True Positive}$  *  $\text{minNeg} = 0.4$ 
for all  $i \in \{1, \dots, 2N\}$ 
  anchor =  $z_i$ 
  for all  $j \in \{1, \dots, 2N\}$  do
     $\text{sim}_{ij} = z_i \cdot z_j / \|z_i\| \|z_j\|$  // cosine similarity
    if  $\text{sim}_{ij} > T2$ 
       $j$  is TP and attract to  $i$ 
    else if  $\text{sim}_{ij} < T1$ 
       $j$  is TN and repel  $i$ 
      if  $\text{sim}_{ij} < \text{minNeg}$ 
         $z_{\text{minNeg}} = z_j$ 
         $\text{minNeg} = \text{sim}_{ij}$ 
      if  $T1 < \text{sim}_{ij} < T2$ 
         $j$  is FN
         $\text{sim}_{\text{minNeg},j} = z_{\text{minNeg}} \cdot z_j / \|z_{\text{minNeg}}\| \|z_j\|$ 
        if  $\text{sim}_{\text{minNeg},j} > \text{sim}_{ij}$ 
           $j$  is TN and repel anchor
        else
           $j$  is TP and attract to anchor

```

فاز دوم: استخراج ویژگی


در طول فرآیند استخراج ویژگی از هر دو نوع سیگنال و تصویر، رویکرد پژوهش در ادامه تشریح شده است.

✓ استخراج ویژگی از سیگنال

در واقع، همان‌طور که در شکل ۴ نشان داده شده است، سیگنال اولتراسوند یک‌بعدی از یک فرآیند کانولوشن یک‌بعدی عبور می‌کند. این معماری شامل ۴ لایه کانولوشن، ۴ تابع فعال‌سازی ReLU، ۲ لایه ادغام و ۲ لایه دورریز با نرخ ۰/۴ است. جزئیات دقیق این معماری در شکل ۴ آمده است.

✓ استخراج ویژگی از تصویر

در این مرحله، ویژگی‌های تصاویر اولتراسوند که از تبدیل سیگنال به دست آمده‌اند، استخراج می‌شود (با استفاده از بازنمایی دانش معماری پیشنهادی خودنظارتی که بر اساس سه مجموعه داده بزرگ آموزش دیده‌اند). هدف از به‌کارگیری این معماری، ایجاد یک چارچوب پایدار و همه‌منظوره است. این ساختار همچنین انعطاف‌پذیری لازم برای مدیریت انواع مختلف داده‌های ورودی، از جمله سیگنال و تصویر، را فراهم می‌کند. علاوه بر این، در شرایطی که ورودی‌های تصویری محدود هستند، برای استخراج ویژگی بسیار کارآمد عمل می‌کند. پس از استخراج ویژگی‌های تصویر، ترکیب ویژگی‌های سیگنال و تصویر به یک MLP برای آموزش و آزمایش داده می‌شود.



شکل ۴: استخراج ویژگی سیگنال

جدول ۲: فراپارامترها برای آموزش یادگیری خودنظارتی

مقدار	فراپارامترها
۱۰۰-۳۰۰	تعداد اپوک
	RMSprop without lr RMSprop with lr=2e-5 Adam with lr=0.0001 Adam with lr=2e-5 or 0.00002 Adam with lr=0.001 LARS without lr LARS with lr=0.01
	RMSprop Adam LARS
	الگوریتم‌های بهینه سازی
	infoNCE NT_Xent HWCSL
	تابع ضرر
	اندازه بچ
	نرخ یادگیری
	پارامتر دما

نتایج

روش پیشنهادی به دقت برای تحلیل داده‌های اولتراسوند بهینه‌سازی شده است. به‌ویژه، در پردازش داده‌های تصویری اولتراسوند، از الگوریتم‌های متعارف فاصله گرفته و تطبیق‌های ویژه‌ای در ساختار یادگیری عمیق خودنظارتی متضاد معرفی گردیده است. این اصلاحات که به‌طور خاص برای تصاویر پزشکی B-mode تنظیم شده‌اند، دقت را به‌طور قابل‌توجهی نسبت به روش‌های سنتی افزایش داده‌اند. برای بهبود عملکرد طبقه‌بندی، ابتدا دانش ضروری از مجموعه داده‌های بزرگ استخراج شد. سپس شبکه که بر اساس بازنمایی خودنظارتی طراحی شده بود، تحت آموزش و آزمایش‌های دقیق با استفاده از مجموعه داده‌های تصویری اولتراسوند قرار گرفت. جزئیات کامل تمامی فراپارامترهای مربوط به روش پیشنهادی به‌طور دقیق مستند شده و در جدول ۲ نشان داده شده‌اند.


- معیارهای ارزیابی

معیارهای مورد استفاده برای ارزیابی شامل شاخص‌های متنوعی است که با هدف بررسی کارایی تکنیک تازه معرفی‌شده و ارزیابی جایگاه آن در مقایسه با روش‌های پیشرفته انجام می‌شود. ارزیابی روش پیشنهادی شامل چندین معیار کلیدی از جمله دقت (Accuracy)، دقت مثبت یا صحت (Precision)، یادآوری (Recall) و امتیاز F1 می‌شود. دقت، میزان کلی صحت طبقه‌بندی‌ها را اندازه‌گیری می‌کند. دقت مثبت، نسبت موارد مثبت صحیح شناسایی‌شده در میان تمام موارد مثبت پیش‌بینی‌شده را نشان می‌دهد. یادآوری، نسبت موارد مثبت صحیح شناسایی‌شده در میان تمامی موارد مثبت واقعی را بیان می‌کند. امتیاز F1 نیز میانگین هارمونیک متوازن دقت و یادآوری را نشان می‌دهد. تنظیم فراپارامترهای ذکرشده در جدول ۳ می‌تواند تأثیر قابل‌توجهی بر فرآیند یادگیری مدل و عملکرد نهایی آن داشته باشد. با توجه به اندازه‌های متغیر اشیاء در سه مجموعه داده بزرگ متفاوت، اندازه دسته به تناسب تفاوت می‌کند. به هر مجموعه داده اندازه‌های دسته خاصی اختصاص یافته که با مقسوم‌علیه‌های مربوطه هماهنگ است. انتخاب بین LARS و Adam برای یادگیری خودنظارتی به عوامل مختلفی از جمله وظیفه خاص، معماری شبکه عصبی، ویژگی‌های مجموعه داده و منابع محاسباتی موجود بستگی دارد. طبق آزمایش‌ها LARS با دسته‌های بزرگ‌تر بهتر عمل کرد و در مقابل، قدرت Adam در همگرایی سریع به وضوح دیده شد. در نهایت، انتخاب بهینه مستلزم آزمایش و تنظیم دقیق (Fine tuning) مطابق با نیازهای خاص وظیفه یادگیری خودنظارتی و طراحی شبکه عصبی است. در مراحل پیش‌آموزش، نرمال‌سازی تصاویر به رزولوشن ۲۵۶*۲۵۶ انجام شد و از اندازه‌های دسته متغیر در پیش‌آموزش بهره برده شد. در جدول ۳، هیچ‌گونه مقداردهی اولیه تصادفی انجام نشده و تمام شبکه‌ها با وزن‌های پس از پیش‌آموزش با مجموعه داده‌های بزرگ شروع به آموزش کرده‌اند. به این ترتیب، نتایج بهترین فراپارامترها و تنظیمات شبکه پیشنهادی گزارش شده است. علاوه بر این، روش پیشنهادی در مقایسه با SimCLR و MoCo ارزیابی شده است.


جدول ۳: نتایج تجربی انتخاب فرایارامترهای متناسب با هر مجموعه داده جهت پیش‌آموزش به همراه مجموعه داده هدف و مقایسه کارایی معماری پیشنهادی

مجموعه داده پیش‌آموزش + مجموعه داده‌ی هدف				
Deep Lesion(CT image) ⁺	Breast Ultrasound Dataset ⁺	ImageNet ⁺	اندازه دسته	فرایارامترها
۹۶	۷۸	۲۰۰	الگوریتم بهینه‌سازی	فرایارامترها
LARS	LARS	Adams	نرخ یادگیری	
۰/۰۰۰۶	۰/۰۰۵	۰/۰۰۰۱	دقت (%)	
۸۶/۵	۸۵/۳	۸۱/۵	SimCLR	معیارهای سنجش
۸۴/۴	۸۰	۸۳	MoCo	
۸۶/۱	۹۵	۸۵	HWCSSL	
۸۵	۹۰	۸۴	SimCLR	
۸۳/۳	۸۹/۵	۸۲/۷	MoCo	
۸۹	۹۴	۸۷	HWCSSL	
۸۹/۷	۹۱/۵	۸۹	SimCLR	
۹۱	۹۲	۹۱	MoCo	
۹۳/۴	۹۶	۹۴	HWCSSL	
۹۰	۹۳	۸۸	SimCLR	F1-score (%)
۹۰/۶	۹۲/۶۴	۸۷/۸	MoCo	
۹۴/۳۳	۹۵	۹۱/۷	HWCSSL	

روش پیشنهادی برای طبقه‌بندی نواحی جراحی با HIFU به دقت ۹۵٪، دقت مثبت ۹۴٪، یادآوری ۹۶٪ و امتیاز F1 برابر با ۹۵٪ دست یافت. این نتایج اثربخشی روش پیشنهادی را برای طبقه‌بندی نواحی جراحی با HIFU نشان می‌دهند. در شکل ۵ الف، یک تحلیل مقایسه‌ای میان سه روش با استفاده از مجموعه داده‌های مختلف انجام شده است. نتیجه آشکار، عملکرد برتر روش پیشنهادی به‌ویژه با مجموعه داده اولتراسوند است که شباهت بیشتری به داده‌های این مطالعه دارد. در شکل ۵ ب، نمودار سطحی ارائه‌شده تعامل پیچیده میان معیارهای متنوع در سه مجموعه داده مختلف را در مقایسه با روش‌های Moco [۲۷]، SimCLR [۲۸] و روش پیشنهادی این مطالعه (HWCSSL) به تصویر می‌کشد. این تجسم به‌طور مؤثری رابطه چندبعدی بین این معیارها را نشان داده و نمایش عمیق از نحوه تعامل هر روش با مجموعه داده‌ها ارائه می‌دهد. از طریق این تحلیل جامع، تفاوت‌های ظریف در عملکرد روشن می‌شوند و دیدگاهی کلی و ضروری برای درک اثربخشی مقایسه‌ای Moco، SimCLR و روش نوآورانه ما در بستر این مجموعه داده‌ها فراهم می‌شود.



(ب)



(الف)

شکل ۵: مقایسه نموداری روش‌ها با روش پیشنهادی. (الف) مقایسه تجمعی کارایی سه روش بر روی مجموعه داده‌های عظیم مختلف. (ب) نمودار سطح

بحث و نتیجه‌گیری

روش پیشنهادی برای طبقه‌بندی نواحی جراحی با HIFU مبتنی بر شبکه عصبی عمیق خودنظارتی، رویکردی امیدبخش برای بهبود دقت و کارایی درمان HIFU است. استفاده از الگوریتم‌های یادگیری عمیق می‌تواند دقت و کارایی روش‌های پزشکی، از جمله درمان HIFU، را ارتقاء دهد. به طور خلاصه، این روش پیشنهادی در مجموعه داده بزرگ Breast Ultrasound نتایج برتری را نشان داد. بر اساس یافته‌های ارائه شده، روش یادگیری خودنظارتی عملکرد بهتری نشان می‌دهد هنگامی که مجموعه داده بزرگ با مجموعه داده اصلی همخوانی بیشتری داشته باشد. با این حال، برخلاف یادگیری انتقالی، حساسیت این روش به شباهت مجموعه داده‌ها به آن اندازه زیاد نیست. این مطالعه همچنین به کاربرد هم‌زمان یادگیری نظارت شده و خودنظارتی می‌پردازد. در این جا، ویژگی‌های سیگنال به صورت خودکار توسط یادگیری عمیق با نظارت استخراج شده و به صورت موازی ویژگی‌های تصویری نیز استخراج می‌شوند. این رویکرد نوآورانه به طور چشم‌گیری تمایز بین نواحی سالم و جراحی را بهبود داده و از روش‌های موجود پیشی گرفته است. روش پیشنهادی در مقایسه با شبکه‌های عمیق متعارف نوآوری‌های متعددی ارائه می‌دهد:

- ترکیب روش‌های نظارت شده و خودنظارتی برای داده‌های سیگنال و تصویر
- استفاده از تکنیک‌های پیشرفته افزایش داده شامل انتقال، چرخش و تغییرات مبتنی بر موجک
- کدگذار دارای لایه ادغام مبتنی بر موجک و یک تابع خطای متضاد جدید که نمونه‌های منفی دشوار را در نظر می‌گیرد. این روش در مقایسه با روش‌های سنتی طبقه‌بندی نواحی جراحی در HIFU مزایای چندگانه‌ای ارائه می‌دهد. استفاده از شبکه عصبی عمیق خودنظارتی با کمک داده‌های سیگنال و تصویر اولتراسوند، دقت طبقه‌بندی را بهبود بخشیده و فرآیند طبقه‌بندی را بهینه می‌کند.

پیشنهادهای برای کارهای آینده

- چالش‌های مربوط به مجموعه داده‌های کوچک: توسعه راهکارهایی برای مدیریت کمبود داده در تصویربرداری پزشکی.
- پیشرفت در یادگیری خودنظارتی: بهبود تکنیک‌های خودنظارتی برای سیگنال‌های اولتراسوند RF
- استقرار بلادرنگ: تمرکز بر اجرای روش برای پایش HIFU در محل
- اعتبارسنجی در مجموعه داده‌های متنوع: اعتبارسنجی روش در سناریوها و شرایط بالینی مختلف

- افزایش قابلیت تفسیر: ارتقای قابلیت تفسیر مدل برای درک بهتر در محیط‌های بالینی
- آزمایش‌های بالینی و اعتبارسنجی: انجام آزمایش‌های گسترده برای ارزیابی کارایی و ایمنی در استفاده بالینی.

تشکر و قدردانی

نویسندگان از دکتر هادی قاسمی‌فرد در دانشگاه علوم پزشکی مشهد برای ارائه داده‌ها جهت اجرای روش پیشنهادی روی آن‌ها تشکر می‌کنند.

تعارض منافع

نویسندگان اعلام می‌دارند که هیچ‌گونه منافع متضادی وجود ندارد.

حمایت مالی

برای این پژوهش هیچ منبع مالی وجود ندارد. نمونه داده اصلی در آزمایشگاه دانشگاه رایسون، کانادا ثبت شده و مجموعه داده بزرگ دیگری نیز استفاده شده که در وبسایت Kaggle در دسترس است.

کد اخلاق

این پژوهش دارای کد اخلاق IR.KMU.REC.1404.114 از کمیته اخلاق دانشگاه علوم پزشکی کرمان می‌باشد.

مشارکت نویسندگان

متینه زوار، حمیدرضا غفاری، حمید طباطبایی همه افرادی که در اینجا فهرست شده‌اند در تهیه مقاله متعهد بوده و از مشارکت خود آگاه بودند. نویسنده اول آزمایش‌ها را انجام داده، کد را پیاده‌سازی کرده و پیش‌نویس مقاله را با حمایت نویسندگان دوم و سوم نوشته است. نویسندگان دوم و سوم نظارت کرده، ایده را تأیید کرده و اصلاحاتی را در مقاله انجام داده‌اند. همچنین نویسنده دوم، نویسنده مسئول مکاتبات هستند.

References

- [1]. Jiang D, Zhu L, Tong S, Shen Y, Gao F, Gao F. Photoacoustic imaging plus X: a review. Journal of Biomedical Optics 2024;29(S1):S11513. <https://doi.org/10.1117/1.JBO.29.S1.S11513>
- [2]. Ali AR, Samir AE, Guo P. Self-supervised learning for accurate liver view classification in ultrasound images with minimal labeled data. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2023 p. 3087-93.
- [3]. Ayzenberg V, Behrmann M. Development of visual object recognition. Nature Reviews Psychology 2024;3(2):73-90.
- [4]. Li L, Dou ZY, Peng N, Chang KW. Desco: Learning object recognition with rich language descriptions. Advances in Neural Information Processing Systems 2023;36:37511-26.
- [5]. Atmakuru A, Chakraborty S, Faust O, Salvi M, Barua PD, Molinari F, et al. Deep learning in radiology for lung cancer diagnostics: A systematic review of classification, segmentation, and predictive modeling techniques. Expert Systems with Applications 2024;124665. <https://doi.org/10.1016/j.eswa.2024.124665>
- [6]. Reyna MA, Deepanshi WJ, Koscova Z, Elola A, Seyedi S, Campbell K, et al. Digitization and classification of ecg images: The george b. moody physionet challenge 2024. Computing in Cardiology 2024;51:1-4.
- [7]. Tang K, Zhang P, Zhao Y, Zhong Z. Deep learning-based semantic segmentation for morphological fractography. Engineering Fracture Mechanics 2024;303:110149. <https://doi.org/10.1016/j.engfracmech.2024.110149>
- [8]. Rayed ME, Islam SS, Niha SI, Jim JR, Kabir MM, Mridha MF. Deep learning for medical image segmentation: State-of-the-art advancements and challenges. Informatics in Medicine Unlocked. 2024 Apr 22;101504. <https://doi.org/10.1016/j.imu.2024.101504>
- [9]. Liu TA, Koseoglu ND, Jones C. Self-supervised deep learning—the next frontier. JAMA Ophthalmol. 2024;142(3):234. doi:10.1001/jamaophthalmol.2023.6650



- [10]. Cho K, Kim KD, Nam Y, Jeong J, Kim J, Choi C, et al. CHESS: Chest X-Ray Pre-trained model via self-supervised contrastive learning. *Journal of Digital Imaging* 2023;36(3):902-10.
- [11]. Chen X, Wang X, Zhang K, Fung KM, Thai TC, Moore K, et al. Recent advances and clinical applications of deep learning in medical image analysis. *Medical Image Analysis* 2022;79:102444. <https://doi.org/10.1016/j.media.2022.102444>
- [12]. Takagi R, Koseki Y. Noise reduction technique using deep learning for ultrasound imaging during high-intensity focused ultrasound treatment. *Japanese Journal of Applied Physics* 2022;61(SG):SG1069.
- [13]. Liu X, Zhang F, Hou Z, Mian L, Wang Z, Zhang J, Tang J. Self-supervised learning: Generative or contrastive. *IEEE Transactions on Knowledge And Data Engineering* 2021;35(1):857-76. doi: 10.1109/TKDE.2021.3090866
- [14]. Khojaste-Sarakhsi M, Haghighi SS, Ghomi SF, Marchiori E. Deep learning for Alzheimer's disease diagnosis: A survey. *Artificial Intelligence in Medicine* 2022;130:102332. <https://doi.org/10.1016/j.artmed.2022.102332>
- [15]. Loddo A, Buttau S, Di Ruberto C. Deep learning based pipelines for Alzheimer's disease diagnosis: a comparative study and a novel deep-ensemble method. *Computers in Biology and Medicine* 2022;141:105032. <https://doi.org/10.1016/j.combiomed.2021.105032>
- [16]. Obuchowicz R, Strzelecki M, Piórkowski A. Clinical applications of artificial intelligence in medical imaging and image processing—A review. *Cancers* 2024;16(10):1870. <https://doi.org/10.3390/cancers16101870>
- [17]. Ciga O, Xu T, Martel AL. Self supervised contrastive learning for digital histopathology. *Machine Learning with Applications* 2022;7:100198. <https://doi.org/10.1016/j.mlwa.2021.100198>
- [18]. Sowrirajan H, Yang J, Ng AY, Rajpurkar P. MoCo-CXR: MoCo pretraining improves representation and transferability of chest X-ray models, 2021. arXiv:2010.05352. <https://doi.org/10.48550/arXiv.2010.05352>
- [19]. Azizi S, Mustafa B, Ryan F, Beaver Z, Freyberg J, Deaton J, et al. Big self-supervised models advance medical image classification. In *Proceedings of the IEEE/CVF International Conference On Computer Vision* 2021. p. 3478-88.
- [20]. Li G, Togo R, Ogawa T, Haseyama M. Self-supervised learning for gastritis detection with gastric x-ray images. *International Journal of Computer Assisted Radiology and Surgery* 2023;18(10):1841-8.
- [21]. Li G, Togo R, Ogawa T, Haseyama M. COVID-19 detection based on self-supervised transfer learning using chest X-ray images. *International Journal of Computer Assisted Radiology and Surgery* 2023;18(4):715-22.
- [22]. Hu SY, Wang S, Weng WH, Wang J, Wang X, Ozturk A, et al. Self-supervised pretraining with DICOM metadata in ultrasound imaging. In *Machine Learning for Healthcare Conference 2020 Sep 18; PMLR; 2020*. p. 732-49.
- [23]. Chen C, Kim Y, Audigier C, Bector EM. Ultrasound thermometry using an ultrasound element and deep learning for HIFU. In *2019 IEEE International Ultrasonics Symposium (IUS); 2019 Oct 6-9; Glasgow, UK: IEEE; 2019*. p. 548-51. doi: 10.1109/ULTSYM.2019.8926186
- [24]. Rangraz P, Behnam H, Shakhssalim N, Tavakkoli J. A feed-forward neural network algorithm to detect thermal lesions induced by high intensity focused ultrasound in tissue. *Journal of Medical Signals & Sensors* 2012;2(4):192-202.
- [25]. Ghasemifard H, Behnam H, Tavakkoli J. Toward high-intensity focused ultrasound lesion quantification using compressive sensing theory. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine* 2017;231(12):1152-64.
- [26]. Zavar M, Rahati S, Akbarzadeh-T MR, Ghasemifard H. Evolutionary model selection in a wavelet-based support vector machine for automated seizure detection. *Expert Systems with Applications* 2011;38(9):10751-8. <https://doi.org/10.1016/j.eswa.2011.01.087>
- [27]. He K, Fan H, Wu Y, Xie S, Girshick R. Momentum contrast for unsupervised visual representation learning. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* 2020. p. 9729-38.
- [28]. Chen T, Kornblith S, Norouzi M, Hinton G. A simple framework for contrastive learning of visual representations. In *International Conference on Machine Learning; 2020 Nov 21; PmlR; 2020*. p. 1597-607.