لیزر در پزشکی ۱۴۰۱/ دوره ۱۹ / شماره (۲) / صفحات ۳۱-۲۲.

مقاله پژوهشی

بهبود کیفیت تصاویر پخش نوری از تومور سینه با استفاده از هوش مصنوعی

انیس میسمی[۱]
محمدعلی انصاری[۲*]

۱- دانشجوی کارشناسی ارشد فوتونیک، گروه فوتونیک، آزمایشگاه تصویربرداری نوری زیستی، پژوهشکده لیزر و پلاسما، دانشگاه شهید بهشتی، تهران، ایران

۲- استادیار گروه فوتونیک، آزمایشگاه تصویربرداری نوری زیستی، پژوهشکده لیزر و پلاسما، دانشگاه شهیدبهشتی، تهران، ایران

نویسندهٔمسئول: محمدعلی انصاری

پست الکترونیکی: m_ansari@sbu.ac.ir

شماره تماس: ۰۹۱۲۲۵۸۶۴۳۷

خلاصه

مقـــدمه: تصویربرداری پخش نوری یک تکنیک تصویربرداری غیرتهاجمی و غیرمخرّب است که از امواج الکترومغناطیسی در محدوده طول موجِ فروسرخ نزدیک برای اندازه‌گیری ویژگی‌های اپتیکی بافت زیستی نظیر جذب و پراکندگی از مرزهای محیط استفاده می‌کند. عواملی چون پراکندگی بسیار زیاد نور در بافت‌های زیستی و تعداد محدود اندازه‌گیری‌ها سبب‌شده مسئله بازسازی تصویر در این تکنیک چالش‌برانگیز شود. اخیراً شبکه‌های عصبی ژرف به حوزه بازسازی تصویر وارد شده‌اند و توانسته‌اند عملکرد بسیار خوبی از خود نشان دهند. در این پژوهش، روشی جدید برپایه یادگیری ژرف برای حلّ این مسئله ارائه شده است.

روش بررسی: برای پیاده‌سازی این روش با استفاده از شبیه‌سازی رایانه‌ای، بافت‌هایی مکعبی‌شکل با ابعاد $64 \times 64 \times 64\ mm^3$ با تومورهایی در عمق ۲۱ تا ۴۲ میلی‌متری ایجاد گردید. برای اندازه‌گیری از مرز بافت، شبکه‌ای ۵×۵ از منابع و آشکارسازها در طرفین بافت تعبیه کردیم. برای انجام عمل بازسازی، دو شبکه عصبی ژرف با معماری کاملاً متصّل و کانوولوشنی دوبعدی ایجاد نمودیم.

یافته‌ها: برای سنجش کارایی این الگوریتم‌ها، عملکرد آنها را با یکی از روش‌های کلاسیک برپایه‌ی مدل یعنی روش گرادیان مزدوج مقایسه کردیم. برای مقایسه این روش‌ها از معیارهایی چون میانگین خطای مطلق (MAE)، خطای حداقل مربّعات (MSE)، بیشینه سیگنال به نویز (PSNR) و شاخص شباهت ساختاری (SSIM) استفاده شد. نتایج به‌دست‌آمده نشان داد که MSE به‌صورت میانگین ۸۶ درصد و MAE تا ۸۱ درصد کاهش داشته و PSNR دو برابر افزایش یافته است.

نتیجه‌گیری: نتایج این پژوهش نشان داد که استفاده از شبکه‌های مصنوعی ژرف در مقایسه با روش‌های بازسازی کلاسیک جهت بازسازی تصاویر پخش نوری می‌تواند موجب بهبود کیفیت تصاویر به‌دست‌آمده شود.

واژه‌های کلیدی: تصویربرداری زیستی نوری، تصویربرداری پخش نوری، یادگیری ماشین، یادگیری ژرف، هوش مصنوعی، مسئله معکوس، بازسازی تصویر

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

مقـدمه

تصویربرداری زیستی یک تکنیک تصویربرداری غیرتهاجمی است که هدف آن، نمایان کردن فرآیندها و فعالیّت‌های زیستی در یک دوره زمانی خاص است. این فرآیند هیچ‌گونه دخالتی بر روی فرآیندهای حیاتی مانند حرکت، تنفّس و... نداشته و می‌تواند بدون دخالت فیزیکی، در دستیابی به اطّلاعات گسترده‌ای از ساختار آناتومی نمونه‌ی مورد آزمایش گرفته تا غلظت مولکول‌هایِ نشانگر زیستی کمک کند. در این فرآیند به‌طور معمول می‌توان از نور، فلوئورسانس، الکترون، موج فراصوت، پرتو ایکس، تشدید مغناطیسی و پوزیترون به‌عنوان منابع تصویربرداری استفاده کرد (۱).

یکی از روش‌های نوین تصویربرداری نوری، روش پخش نوری نام دارد که در آن از امواج نوری در محدوده طول موجیِ فروسرخ نزدیک (۷۰۰ تا۱۱۰۰ نانومتر) برای دستیابی به ویژگی‌های اپتیکی بافت زیستی از اندازه‌گیری‌های مرزی استفاده می‌شود. در محیط‌های نظیر بافت به‌دلیل پراکندگی بسیار زیاد نور، تعداد فوتون‌هایی که بدون پراکندگی یا با پراکندگی جزئی عبور می‌کنند نادربوده و در مرزهای بافت، بیشتر فوتون‌های پخش‌شده در آشکارسازها دریافت می‌گردد. برهمین‌اساس، در اوایل دهه ۱۹۹۰ میلادی الگوریتم‌هایی که از فوتون‌های پخش‌شده برای بازسازی تصاویر و درنهایت رسیدن به پارامترهای داخلی بافت همانند ضریب جذب و پراکندگی استفاده می‌کردند، پیشنهاد شد (۲-۴) اندازه‌گیری این پارامترهای نوری می‌تواند در دستیابی به اطّلاعاتی در مورد عملکرد و ساختار بافت مفید باشد.

تصویربرداری به این روش در مقایسه با دیگر روش‌های تصویربرداری دارای مزایایی مانند کاهش ابعاد چینش آزمایشگاهی، هزینه پایین و صرف زمان کمتر است اما کم‌بودن وضوح تصویر کاربردهای کلینیکی آن را محدود کرده است. این روش تا به حال در تصویربرداری تومورهای سینه (۵ و۶) ، تصویربرداری از مغز نوزادان (۷)، تصویربرداری عملکردی[1] از مغز بزرگسالان (۸ و۹) و تصویربرداری از مغز حیوانات کوچک (۱۰) استفاده شده است.

الگوریتم‌های این روش شامل دو قسمت است: مسئله مستقیم که در آن شدت نور عبوری و یا بازتاب شده از مرز بافت که برمبنای معادلات پخش مدل‌سازی‌شده، محاسبه‌گردیده و در مسئله معکوس (بازسازی تصویر) به‌دنبال یافتن توزیع ویژگی‌های اپتیکی از این اندازه‌گیری‌های مرزی هستیم (۱۱).

ماهیت مسئله پخش نور در بافت، از لحاظ ریاضیاتی بدتعریف و غیرخطی است چرا که ما ویژگی‌های سیستم را به‌طور کامل نمی‌شناسیم و این مسئله، بازسازی تصویر را با چالش روبه‌رو می‌سازد. الگوریتم‌های خطّی و غیرخطّی متعدّدی جهت حلّ این مسئله ابداع شده‌اند. یکی از رایج‌ترین روش‌ها، روش غیرخطیِ بهینه‌سازی برپایه تکرار است. در این روش، توزیع خواص اپتیکی ازطریق کمینه‌سازی مکرر تابع خطا بین داده‌های محاسباتی و داده‌های اندازه‌گیری‌شده، به مقادیر واقعی نزدیک گشته و درنهایت به تصویر مدنظر می‌رسیم. این روش و سایر روش‌های غیرخطی مشابه از ضعف‌هایی چون محاسبات سنگین، نیاز به فضای ذخیره‌سازی بزرگ و صرف زمان طولانی رنج‌برده و تصاویر بازسازی‌شده دقّت و کیفیّت محدودی دارند؛ بنابراین گسترش و کلینیکی‌شدن این روش نیازمند توسعه الگوریتم‌های بازسازی کارآمدتر است.

یادگیری ژرف زیرشاخه‌ای از هوش مصنوعی و یادگیری ماشین است که در آن از الگوریتم شبکه‌های عصبی مصنوعی استفاده می‌شود. در این روش، رایانه‌ها الگوهای مفید را به‌طور خودکار از داده‌های خام یادگرفته و ویژگی‌های آن را استخراج می‌کنند. استفاده از یادگیری ماشین و یادگیری ژرف در بازسازی تصاویر حاصل از تکنیک‌های مختلف تصویربرداری پزشکی از دهه ۱۹۹۰ آغاز شده است و تاکنون در روش‌هایی چون MRI[2] (۱۲) ، تصویربرداری x-ray (۱۳) ، فوتوآکوستیک[3] (۱۴) و فراصوت[4] (۱۵) بکار رفته است. اخیراً در چند پژوهش از شبکه‌های عصبی مصنوعی و یادگیری ژرف جهت بازسازی تصاویر حاصل از پخش نوری استفاده شده است (۱۶و ۱۷) و نشان داده‌شده که این روش‌ها عملکردی بهتر از روش‌های کلاسیک غیرخطی دارند. در روش‌های کلاسیک برای رسیدن به جواب، مسئله باید به‌صورت دقیق مهندسی شود تا بتوان به جواب رسید درحالی‌که در شبکه‌های عصبی ژرف از هیچ دانش اولیّه‌ای بهره نبرده و تنها با استفاده از مجموعه داده‌های بزرگ شروع به یادگیری ناشناخته‌ها کرده تا در نهایت مسئله معکوس را حل کنیم.

[1] Functional imaging

[2] Magnetic Resonance Imaging: MRI

[3] Photoacoustic

[4] Ultrasound

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

در این پژوهش ابتدا با استفاده از تصاویر ماموگرافی و فراصوت از تومورهای سرطان سینه، مجموعه داده‌ای ۱۷۰۰۰ تایی از بافت‌های سه‌بعدی مکعبی شکل با ضریب جذب پس‌زمینه $۰٫۰۱ mm^{-1}$ و با تک تومورهایی نامتقارن با ضرایب جذب ۰٫۰۲، ۰٫۰۴، ۰٫۰۶ و ۰٫۰۸ بر میلی‌مترایجاد نمودیم. سپس به‌سراغ استفاده از شبکه‌های عصبی مصنوعی کاملاً متصل[1] و کانوولوشنی[2] جهت بازسازی توزیع ضرایب جذب درونی رفتیم. درنهایت عملکرد این شبکه‌ها را در مقایسه با روش کلاسیک گرادیان مزدوج، با استفاده از شاخص‌های ارزیابی تصویر سنجیدیم.

روش بررسی

تولید دیتاست

در این پژوهش، برای ایجاد یک فانتوم دیجیتال سه‌بعدی از یک بافت دارای تومور، از تصاویر واقعی تومورهای سینه استفاده شده است. برای این کار با جستجو در موتورهای جستجوی گوگل‌دیتاست، کگل[3] درنهایت به تصاویر بخش‌بندی‌شده تومور پستان دست یافتیم که به کمک روش‌های تصویربرداری ماموگرافی (۱۸ و ۱۹) و فراصوت (۲۰) به‌دست آمده بود. این تصاویر شامل تومورهای خوش‌خیم و بدخیم سرطان سینه هستند. نمونه‌هایی از این تصاویر در شکل ۱ آمده است. این تصاویر را پس از تغییر اندازه و باینری‌سازی به شکل یک ماتریس سه بعدی درآورده تا بتوانیم برای ایجاد مش‌ها (شبکه‌ها) از آن استفاده کنیم.

تولید مش

برای ایجاد شبکه (مش) از ماتریس‌های سه‌بعدی، از بسته نرم‌افزاری Iso2mesh استفاده شده است (۲۱). این بسته شامل مجموعه‌ای از کتابخانه‌هاست که در نرم‌افزار Matlab قابل اجرا بوده و می‌تواند از تصاویر سگمنت‌شده‌ی دودویی مش‌های سطحی و حجمی بسازد. در اینجا ما از تصاویر موردنظر ناحیه‌ای با ابعاد $64 \times 64 \times 64$ mm^3 با بیشینه حجم المان ۳ در واحد وکسل و اندازه نقطه ۱ ایجاد نمودیم. هر شبکه تومورهایی در عمق ۲۱ تا ۴۲ میلی‌متری خود داراست. در شکل ۲ تصویری از شبکه تولیدشده نشان داده شده است. این شبکه دارای ۲۸۷۰۶ گره و ۱۶۵۹۸۰ المان چهاروجهی یا تتراهدرال است. برای این‌که ببینیم این میزان چگالی مش بهینه است یا خیر، اندازه المان‌ها را کاهش دادیم تا مش چگال‌تر شود. مشاهده شدکه با افزایش چگالی مش بیشتر از این مقدار، تغییرات قابل ملاحظه‌ای در حلّ مسئله معکوس رخ نداد. بنابراین این تعداد گره و المان مقدار بهینه‌ای برای مسئله‌ی ما بوده و مسئله همگرا شده است.

سیستم تصویربرداری

در طراحی سیستم تصویربرداری از ۲۵ منبع و آشکارساز در بالا و پایین نمونه استفاده شده است. هر یک از منابع و آشکارسازها در فاصله ۱۰ mm یکدیگر قرار گرفته‌اند. پروفایل منابع و آشکارسازها گاوسی و شعاع هر یک ۲mm در نظر گرفته شده است. در شکل ۳ آرایش منابع و آشکارسازها نمایش داده شده است.

حل مسئله مستقیم پخش

برای حل مسئله مستقیم پخش از بسته نرم‌افزاری Toast++ استفاده کردیم (۲۲). این بسته در داخل محیط نرم‌افزار متلب قابل اجرا است. در اینجا، مسئله مستقیم پخش در مد پیوسته و با فرکانس مدولاسیون صفر حل شده است. در مجموع ۱۷۰۰۰ فانتوم سه‌بعدی ساخته شد که دارای ضریب جذب زمینه $۰٫۰۱ mm^{-1}$ و ضریب پراکندگی $۱ mm^{-1}$ و ضریب شکست ۱٫۴ هستند. محلّ قرارگیری تومورها در عرض و طول فانتوم تصادفی بوده و دارای ضرایب جذب ۰٫۰۲، ۰٫۰۴، ۰٫۰۶ و۰٫۰۸ بر میلی‌متر هستند. پس از حل مسئله مستقیم نویز تصادفی۰٫۰۱ درصد اضافه‌شده تا شرایط آزمایشگاهی را شبیه‌سازی کند. درنهایت دو خروجی از این مسئله به‌دست آمد: ۶۲۵ اندازه‌گیری مرزی و ماتریسی سه‌بعدی از ضرایب جذب درونی بافت جهت تسهیل نمایش آنها. ایجاد یک ماتریس سه‌بعدی این امکان را می‌دهد که ضرایب جذب را به صورت پشته‌ای از تصاویر داشته باشیم. دلیلی که ضریب پراکندگی بافت در همه‌جا یکسان درنظر گرفته‌شده این است که در مدل‌سازی مد پیوسته[4] نمی‌توان از مسیر و زمان حرکت نور اطّلاعی به‌دست آورد و قادر به بازسازی هم زمان ضرایب جذب و پراکندگی نیستیم.

[1] Fully Connected Neural Network: FCNN
[2] Convolutional Neural Network: CNN
[3] Kaggle.com
[4] Continuous wave

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

بازسازی تصاویر پخش نوری

بازسازی با روش‌غیرخطی گرادیان مزدوج (روش کلاسیک)

برای حل مسئله معکوس پخش از روش گرادیان مزدوج بهره‌گرفته و برای کاهش بدتعریفی مسئله از تابع تنظیم‌ساز تفاوت کامل[1] با هایپرپارامتر ۰٫۰۰۱ استفاده شده است. حداکثر تعداد تکرار برای به‌روزرسانی ضرایب جذب با توجه به هر مسئله از ۱۰۰ تا ۱۵۰ متغیر بود.

بازسازی تصویر با استفاده از شبکه‌های عصبی ژرف

برای انجام عمل بازسازی با استفاده از شبکه‌های عصبی ژرف، دو شبکه عصبی با معماری کاملاً متصّل و کانوولوشنی دوبعدی ایجاد نمودیم. هایپرپارامترهای آموزشی این روش مانند نرخ یادگیری و بهینه‌ساز، با روش جستجوی شبکه‌ای[2] انتخاب شد. در این روش با امتحان مقادیر مختلف برای یک پارامتر بر روی داده‌های ارزیاب و با کمک منحنی یادگیری بهترین مقدار آن پارامتر را پیدا می‌کنند. خطای آموزشی هر دو شبکه، خطای میانگین مربّعات و شاخص ارزیابی در هر دور (ایپاک[3])، خطای میانگین مطلق در نظر گرفته شد.

شبکه عصبی با لایه‌های کاملاً متّصل:

برای آموزش این شبکه از ۱۰۰۰ دور آموزشی و اندازه دسته ۱۲۸ و تکنیک توقّف زودهنگام[4] جهت جلوگیری از بیش‌برازش[5] استفاده شده است. علاوه‌بر این برای بهبود شبکه، یک لایه نویز گاوسی ۰٫۱ اضافه شد. مشاهده شد که این لایه عملکرد شبکه را بهبود بخشیده است. داده‌های آموزشی، آزمایشی و ارزیابی این شبکه به ترتیب به‌صورت نسبت ۷۰، ۲۰ و ۱۰ درصد درنظر گرفته شده است؛ بنابراین ۱۲۲۴۰ داده‌ی آموزشی، ۳۴۰۰ داده آزمایشی و ۱۳۶۰ داده ارزیاب داریم. داده‌های ورودی که همان اندازه‌گیری‌های مرزی ما هستند با لگاریتم‌گیری و نرمال‌سازی، استانداردشده و روی داده‌های خروجی هیچ‌گونه پیش‌پردازشی صورت نگرفته است. در هر لایه تابع فعال‌ساز رلو[6] به‌کار برده‌شده و برای بهبود فرآیند یادگیری از بهینه‌ساز آدام[7] با نرخ یادگیری ۰٫۰۰۰۱ استفاده شده است. این شبکه با بهینه‌سازهای دیگری چون گرادیان کاهشی تصادفی نیز امتحان شد. نرخ یادگیری اوّلیّه این شبکه ۰٫۰۱ در نظر گرفته شد (با آزمون و خطا) و در طول هر اپیاک (دور) به‌صورت نمایی کاهش می‌یافت، امّا نتوانست عملکردی بهتر از بهینه‌ساز آدام داشته باشد. معماری شبکه در جدول ۱ آمده است.

شبکه عصبی کانوولوشنی

در اینجا یک شبکه کانوولوشنی با ۶ لایه کانوولشنی به همراه یک لایه کاملاً متّصل ایجاد شده است. معماری این شبکه در جدول ۲ آمده است. تعداد دور آموزشی ۱۰۰۰ و اندازه دسته برابر ۱۲۸ است. تعداد پارامترهای این شبکه نسبت به شبکه قبل کمتر است که این البتّه یکی از مزیّت‌های این نوع شبکه است چرا که با کاهش پارامترهای آموزشی عملاً ویژگی‌های بدون اهمیّت از مسئله خارج می‌شوند. در اینجا هم از همان تعداد داده آموزشی، آزمایشی و ارزیابی استفاده‌شده و تابع فعال‌ساز رلو به همراه بهینه‌ساز آدام با همان نرخ یادگیری به کاربرده شده است. نکته‌ای که در اینجا وجود دارد این است که آموزش شبکه کانوولوشنی در مقایسه با دیگر شبکه‌ها زمان برتر است. برای سرعت بخشیدن به این روند از پردازشگر گرافیکی GPU که سرویس ابری گوگل‌کولب[8] در اختیارمان گذاشته، استفاده کردیم.

معیارهای ارزیابی

عملکرد الگوریتم‌های ارائه‌شده توسّط روش‌های کلاسیک و یادگیری ژرف توسط معیارهایی چون میانگین خطای مطلق[9]، خطای حداقل مربّعات[10]، بیشینه‌ی سیگنال به نویز[11] و شاخص شباهت ساختاری[12] ارزیابی می‌شود. این پارامترها به‌صورت زیر تعریف می‌شوند:

$$MAE = \frac{\sum_{i=1}^{N}|x_{true}(i)-x_{recon}(i)|}{N} \qquad (۱)$$

$$MSE = \frac{\sum_{i=1}^{N}|x_{true}(i)-x_{recon}(i)|^2}{N} \qquad (۲)$$

[1] Total Variation
[2] Grid search
[3] Epoch
[4] Early stopping
[5] Overfitting
[6] ReLU
[7] Google colab
[9] Mean Absolute Error: MAE
[10] Mean Squared Error: MSE
[11] Peak Signal to Noise Ratio: PSNR
[12] Structural Similarity Index Metric: SSIM

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

$$PSNR = 10\log_{10}\left\{\frac{[\max(x_{recon})]^2}{MSE}\right\} \quad (۳)$$

$$SSIM = \frac{(2\overline{x}_{true}\overline{x}_{recon}+c_1)(2\sigma_{true.recon}+c_2)}{(\overline{x}^2_{true}+\overline{x}^2_{recon}+c_1)(\sigma^2_{true}+\sigma^2_{recon}+c_2)} \quad (۴)$$

که در ان x_{true} و x_{recon} به‌ترتیب ضریب جذب واقعی و بازسازی‌شده و $\overline{x}_p$ (p=reconیا true) و σ_p میانگین و انحراف معیار داده‌های واقعی و بازسازی‌شده هستند. $\sigma_{true.recon}$ کواریانس (هم‌وردایی) بین داده‌های واقعی و بازسازی‌شده و c_1و c_2 ثوابت پایداری مسئله هستند. میانگین خطای مطلق و خطای حداقل مربّعات برای مقایسه دقّت تصویر بازسازی‌شده به‌کار می‌روند. بیشنیه سیگنال به نویز با واحد دسی‌بل نسبتی است بین بیشینه توان یک تصویر و بیشنه نویزی که تصویر را تحت تاثیر قرار می‌دهد. هرچه قدر مقدار آن بیشتر باشد یعنی توانایی بازسازی تصویر بیشتر است. شاخص شباهت ساختاری نیز شباهت بین تصویر واقعی و بازسازی‌شده را نشان می‌دهد و هرچه که به یک نزدیکتر باشد یعنی تصویر ایده‌آل‌تر است. یک بازسازی خوب شامل MAE وMSE کم وPSNR وSSIM بزرگ است.

یافتـه‌ها

عملکرد شبکه‌های عصبی ایجادشده بر روی داده‌های آموزشی و آزمایشی در جدول ۳ آمده است. این جدول نشان می‌دهد که اندازه خطای آموزشی و آزمایشی در هر دو شبکه بسیار به هم نزدیک بوده و شبکه‌های ما دچار بیش‌برازش نشده است؛ بنابراین عمل یادگیری توسط این الگوریتم‌ها به درستی انجام شده است. آموزش هر دو شبکه کمتر از ۱ ساعت زمان برده است.

برای سنجش کارایی روش‌های یادگیری ژرف در بازسازی تصاویر حاصل از پخش نوری، تفاوت شاخص‌های کیفیّت تصویر بازسازی‌شده توسط این روش و روش‌های کلاسیک گرادیان مزدوج در جدول ۴ بیان‌شده و سه نمونه تصویر بازسازی‌شده که دارای تومورهایی با ضرایب جذب ۰٫۰۲، ۰٫۰۴ و ۰٫۰۶ بر میلی‌متر هستند در شکل ۴ نشان داده شده است. بازسازی تصویر به روش گرادیان مزدوج ۳۵۰۰ ثانیه به‌طول انجامیده است که یکی از دلایلش همگرایی آهسته این روش است.

همان‌طورکه از جدول ۴ پیداست، شبکه‌های عصبی ژرف نسبت به گرادیان مزدوج در همه معیارها عملکرد بهتری از خود نشان دادند. به‌طور مثال در فانتومی که مقطعی از آن در بخش سمت چپ شکل ۴ نشان داده‌شده و دارای توموری با ضریب جذب ۰٫۰۲ بر میلی‌متر است، شبکه کاملا متصل و کانوولوشنی توانسته‌اند MSE را به‌ترتیب ۸۴% و ۶۲%، MAE را ۷۶% و ۶۹% و PSNR را تقریباً ۲ برابر کند. نتایج به‌دست آمده نشان داد که MSE به‌صورت میانگین ۸۶ درصد و MAE تا ۸۱ درصد کاهش داشته و PSNR ۲ برابر افزایش یافته است.

بحث ونتیجه‌گیری

تصویربرداری پخش نوری یک تکنیک تصویربرداری غیرتهاجمی و غیرمخرّب است که ظرفیّت زیادی در تصویربرداری از بافت‌های زیستی چون سینه و مغز دارد. عواملی چون پراکندگی بسیار زیاد نور در بافت‌های زیستی و تعداد محدود اندازه‌گیری‌ها سبب شده مسئله‌ی بازسازی تصویر در این تکنیک چالش‌برانگیز شود. الگوریتم‌های خطّی و غیرخطّی متعدّدی جهت حلّ این مسئله ابداع شده‌اند امّا هریک از ضعف‌هایی چون محاسبات سنگین و نیاز به فضای ذخیره‌سازی بزرگ و صرف زمان طولانی رنج‌برده و تصاویر بازسازی‌شده دقّت و کیفیّت محدودی دارند. در این پژوهش، روشی جدید بر پایه یادگیری ژرف برای حلّ این مسئله ارائه شده است. این روش به‌جای وابستگی به فیزیک مسئله، الگوهای موجود در داده‌های مسئله مستقیم پخش را یافته و براساس این الگوها توزیع ضرایب اپتیکی درون بافت را پیش‌بینی می‌کند.

برای پیاده‌سازی این روش ما نیازمند تعداد زیادی داده جهت آموزش الگوریتم‌های آن هستیم. ازآنجاکه این تکنیک تصویربرداری دارای مجموعه داده قابل دسترسی نیست باید در قدم اوّل تعداد زیادی بافت مصنوعی با توزیع‌های اپتیکی مختلف تولیدکرده و با ایجاد یک سیستم تصویربرداری، شدّت نور پخش‌شده از مرز آنها را دریافت نماییم. بدین‌منظور، با استفاده از شبیه‌سازی رایانه‌ای، بافت‌هایی مکعبی‌شکل با ابعاد $64 \times 64 \times 64\ mm^3$ با تومورهایی در عمق ۲۱ تا ۴۲ میلی‌متری ایجاد گردید. شکل این تومورها از تصاویر ماموگرافی و فراصوت دریافت شده است و هر بافت تنها یک تومور دارد. برای اندازه‌گیری از مرز بافت، شبکه‌ای 5×5 از منابع و آشکارسازها در طرفین بافت تعبیه کردیم. درمجموع ۶۲۵ اندازه‌گیری انجام گرفت که برای شبیه‌سازی شرایط

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

آزمایشگاه، با نویز ۱ درصد تصادفی همراه‌شد. داده‌های اندازه‌گیری‌شده نویزدار به‌عنوان ورودی شبکه‌های عصبی ژرف و توزیع ضرایب جذب درون بافت به عنوان خروجی این شبکه‌ها هستند. در مجموع دیتاستی با ۱۷۰۰۰ نمونه برای آموزش شبکه ایجاد نمودیم.

برای انجام عمل بازسازی، دو شبکه عصبی با معماری کاملاً متصّل و کانوولوشنی دوبعدی ایجاد نمودیم. خطای آموزشی هر دو شبکه، خطای میانگین مربّعات و شاخص ارزیابی در هر دور (اپیاک)، خطای میانگین مطلق درنظر گرفته شد. مشاهده شد که اندازه‌ی خطا در دو شبکه چه در دسته آموزشی و چه در دسته آزمایشی با هم تقریباً برابر بوده و شبکه کانوولوشنی مقدار بسیار کمی بهتر عمل کرده است.

برای سنجش کارایی این الگوریتم‌ها، عملکرد آنها را با یکی از روش‌های کلاسیک برپایه مدل یعنی روش گرادیان مزدوج مقایسه کردیم. الگوریتم بازسازی گرادیان مزدوج در مقایسه با روش‌های بهینه‌سازی دیگری چون گاوس - نیوتن دارای بار محاسباتی کمتری بوده امّا سرعت همگرایی آن کم است. حلّ مسئله معکوس به این روش برای هر یک از نمونه‌ها دست‌کم ۳۵۰۰ ثانیه به طول می‌انجامید، این درحالی است که بازسازی تصویر به کمک شبکه‌های عصبی ژرف تنها ۲ تا ۳ ثانیه به طول می‌انجامد. علاوه‌بر صرفه زمانی، نتایج نشان داد که شاخص‌های ارزیابی تصویر نیز بهبود پیدا کرده است و به تصاویری با کیفیت بهتری دست یافته‌ایم.

این روش در مقایسه با سایر پژوهش‌ها در زمینه تصویربرداری پخش نوری از جمله (۲۳-۲۴) دارای وجوه تمایزی ازجمله، تعداد بیشتر نمونه‌ها، سه‌بعدی بودن نمونه‌ها و شکل نامتقارن تومورهای آنهاست. ازآنجاکه بسیاری از تلاش‌های صورت‌گرفته بر روی نمونه‌هایی دوبعدی با تومورهای متقارن دایره‌ای شکل هستند و چیدمان منابع و آشکارسازها به‌صورت ۱۶*۱۶ پیرامون بافت قرار دارد، در این پژوهش به سراغ دیگر شکل‌های بافت رفتیم و چیدمانی متراکم‌تر را درنظر گرفتیم به‌همین‌دلیل امکان مقایسه نتایج این نمونه با سایر پژوهش‌ها وجود ندارد چرا که آنها از نوع هندسه‌های دیگر بافت، چیدمان متفاوت منابع و آشکارسازهای تصویربرداری و معماری‌های شبکه متفاوتی برخوردارند. افزایش تعداد نمونه‌ها هم با توجه به دسترس‌بودن تعداد بسیار اندکی از اندازه‌گیری‌های پخش نوری در مقایسه با سایر روش‌های تصویربرداری مانند امآرآی و سی‌تی اسکن در نوع خود قابل توجه است. مقایسه نتایج نشان داد که واردکردن الگوریتم‌های هوش مصنوعی به این تکنیک تصویربرداری در مقایسه با روش‌های بهینه‌سازی معمول، باعث کاهش زمان بازسازی و افزایش دقت آن شده است. ازجمله چالش‌های ما در این پژوهش این بود که کار ما در دسته نگاشت مستقیم[1] قرار می‌گیرد بدین معنی که یک نگاشت کامل یا جزئی از داده‌های اندازه‌گیری‌شده به تصاویر (در اینجا توزیع پارامترهای اپتیکی) داشته و فیزیک مسئله وارد نمی‌شود. چنین عملی نیازمند دارا بودن تعداد زیادی داده و فضای محاسباتی بزرگ است و این ضعف کار ما نیز حساب می‌شود. بنابراین پیشنهاد می‌شود که از یادگیری ژرف جهت تنظیم عوامل موثر بر بهبود روش‌های بازسازی کلاسیک به‌طور مثال یافتن تابع تنظیم‌سازیِ‌داده محور استفاده کرده و این‌گونه با ترکیب روش‌های کلاسیک و هوش مصنوعی، بازسازی تصاویر پخش نوری از مزیت هر دو روش بهره‌مند شود.

تشکر و قدردانی

این اثر تحت حمایت مالی صندوق حمایت از پژوهشگران و فناوران کشور (INSF) برگرفته از طرح شماره (۹۸۰۲۹۴۶۰) انجام‌شده‌است.

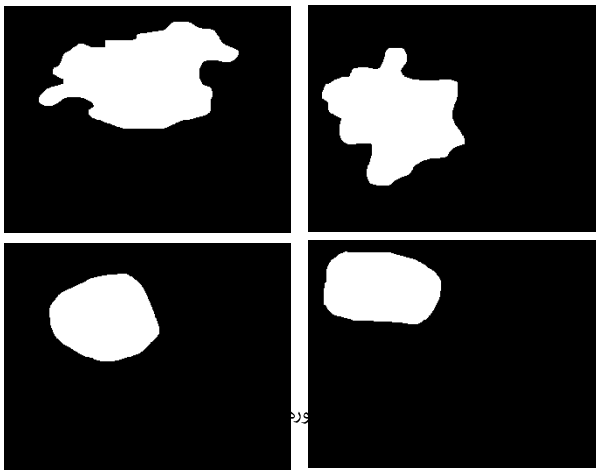

[1] Direct mapping

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

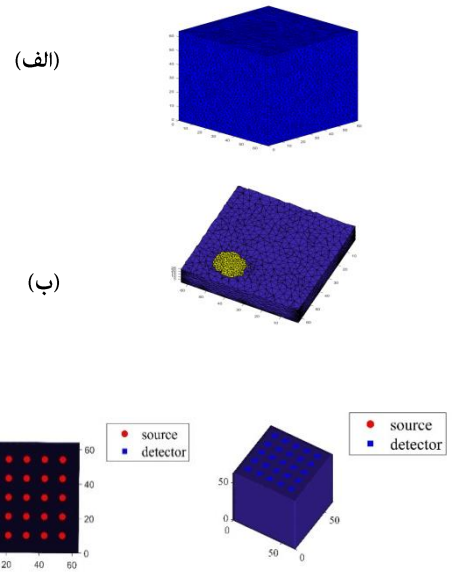

شکل ۲: الف) نمایی کلّی از سطح مش، ب) نمایی از درون مش تولیدی

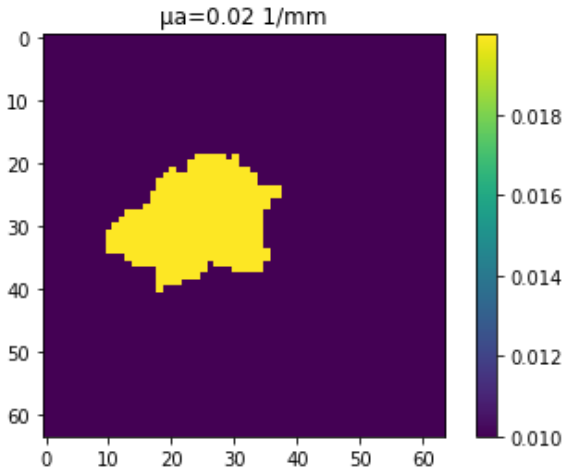

شکل ۳: نمایی از آرایش منابع و آشکارسازها

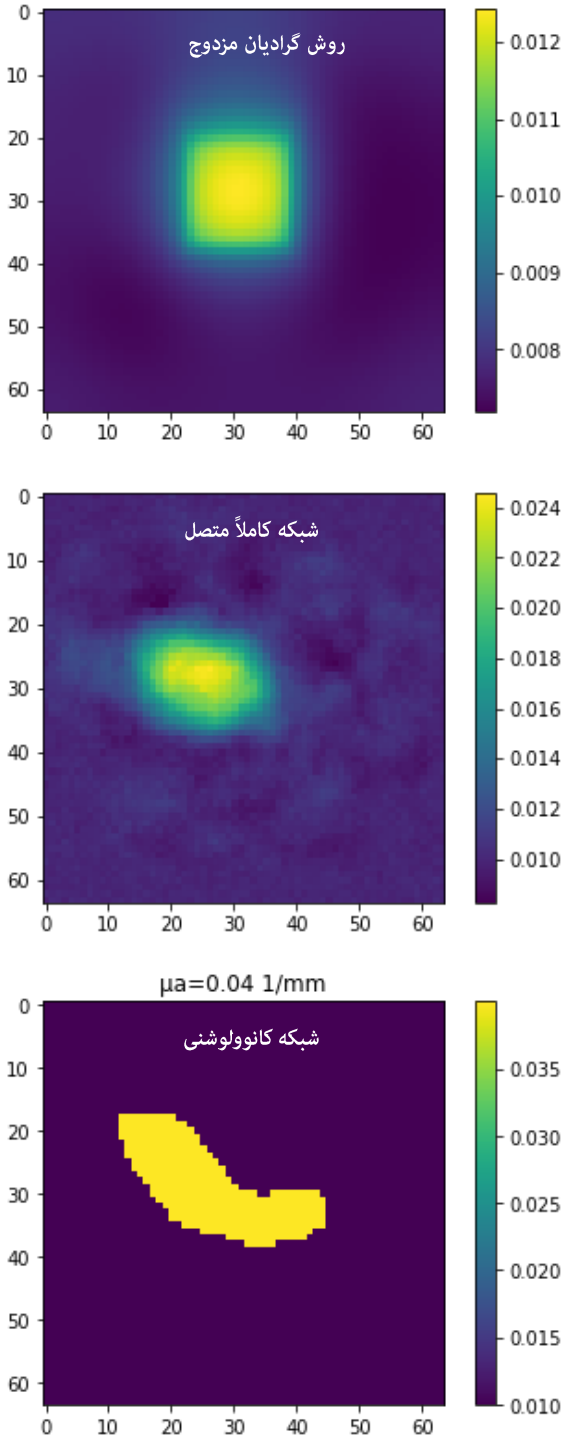

شکل ٤: تصاویر واقعی و بازسازی‌شده توسّط روش گرادیان مزدوج، شبکه کاملاً متصّل و کانوولوشنی در Z=۲۵

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

جدول ۱ معماری شبکه کاملاً متّصل

Layer (Type)	Output shape	Param #	Activation
Input	None	None	None
Dense	(None,256)	۱۶۰۲۵۶	ReLU
Gaussian noise	(None,256)	۰	ReLU
Dense	(None,256)	۶۵۷۹۲	ReLU
Dense	(None,625)	۱۶۰۶۲۵	ReLU
Dense	(None,625)	۳۹۱۲۵۰	ReLU
Dense	(None,625)	۳۹۱۲۵۰	ReLU
Dense	(None,625)	۳۹۱۲۵۰	ReLU
Dense	(None,1024)	۶۴۱۰۲۴	ReLU
Dense	(None,4096)	۴۱۹۸۴۰۰	ReLU
Total Parameters		6399847	
Trainable Parameters		۶۳۹۹۸۴۷	

جدول ۲ معماری شبکه کانوولوشنی

Layer (Type)	Output shape	Param #	Activation
Input	None	None	None
Conv2D	(None,25,25,32)	320	ReLU
Conv2D	(None,25,25,32)	9248	ReLU
Max Pool	(None,12,12,32)	۰	ReLU
Conv2D	(None,12,12,64)	۱۸۴۹۶	ReLU
Conv2D	(None,12,12,64)	۳۶۹۲۸	ReLU
Max Pool	(None,6,6,64)	۰	ReLU
Conv2D	(None,6,6,128)	۷۳۸۵۶	ReLU
Conv2D	(None,6,6,128)	۱۴۷۵۸۴	ReLU
Max Pool	(None,3 ,3,128)	۰	۰
Flatten	(None,1152)	۰	۰
Dense	(None,625)	۷۲۰۶۲۵	ReLU
Dense	(None,4096)	۲۵۶۴۰۹۶	ReLU
Total Parameters		3,571,153	
Trainable Parameters		۳،۵۷۱،۱۵۳	

جدول ۳ خطای شبکه کاملاً متصل و کانوولوشنی

نوع داده	خطای حداقل مربّعات		خطای مطلق
آموزشی	شبکه کاملا متصل	1.69×10^{-5}	۰،۰۰۱۶
	شبکه کانوولوشنی	1.33×10^{-5}	۰،۰۰۱۵
آزمایشی	شبکه کاملاً متصل	2.12×10^{-5}	۰،۰۰۱۷
	شبکه کانوولوشنی	2.03×10^{-5}	۰،۰۰۱۷

جدول٤ مقایسه شاخص‌های کیفیّت تصویر در سه روش گرادیان مزدوج و شبکه‌های عصبی کاملا متصل و کانوولوشنی

روش	ضریب جذب mm^{-1}	MSE	MAE	PSNR (dB)	SSIM
شبکه کاملاً متصّل	۰،۰۲	2.02×10^{-6}	6.88×10^{-4}	۲۴،۷۵	۰،۴۸
کانوولوشنی		4.7×10^{-6}	8.88×10^{-4}	۲۳،۷۶	۰،۵۸
گرادیان مزدوج		1.25×10^{-5}	2.89×10^{-3}	۱۰،۹	۰،۵۷
شبکه کاملاً متصّل	۰،۰۴	1.49×10^{-5}	1.88×10^{-3}	۲۳،۹۶	۰،۵۷
کانوولوشنی		1.07×10^{-5}	1.66×10^{-3}	۲۵،۴۸	۰،۵۹
گرادیان مزدوج		1.52×10^{-4}	1.16×10^{-2}	۱۰،۱۲	۰،۵۶
شبکه کاملاً متصّل	۰،۰۶	1.88×10^{-5}	2.2×10^{-3}	۲۲،۷۲	۰،۵۸
کانوولوشنی		1.38×10^{-5}	1.88×10^{-3}	۲۶،۴۹	۰،۶۴
گرادیان مزدوج		2.83×10^{-4}	1.62×10^{-2}	۹،۵۲	۰،۶

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

References:

1. Powell S, Arridge SR, Leung T S. Gradient-based quantitative image reconstruction in ultrasound-modulated optical tomography: first harmonic measurement type in a linearised diffusion formulation. IEEE transactions on medical imaging .2015; 35(2):456-467.

2. Singer JR, Grünbaum FA, Kohn P, Zubelli JP. Image reconstruction of the interior of bodies that diffuse radiation. Science.1990; 248(4958): 990-993.

3. Arridge SR, Schweiger M, Delpy DT. Iterative reconstruction of near-infrared absorption images. In Inverse Problems in Scattering and Imaging.1992; 1767:372-383.

4. Barbour RL, Graber HL, Lubowsky J, Aronson R, Das BB, Yoo KM, Alfano RR. Imaging of diffusing media by a progressive iterative backprojection method using time-domain data. Physiological Monitoring and Early Detection Diagnostic Methods. 1992 May; 1641: 21-34.

5. Grosenick D, Rinneberg H, Cubeddu R, Taroni P. Review of optical breast imaging and spectroscopy. Journal of biomedical optics. 2016; 21(9): 091311.

6. Cochran J M, Busch DR, Lin L, Minkoff DL, Schweiger M, Arridge S, Yodh AG. Hybrid time-domain and continuous-wave diffuse optical tomography instrument with concurrent, clinical magnetic resonance imaging for breast cancer imaging. Journal of biomedical optics. 2019; 24(5), 051409.

7. Hebden JC, Gibson A, Yusof RM, Everdell N, Hillman EM, Delpy DT, Wyatt J S. Three-dimensional optical tomography of the premature infant brain. Physics in Medicine & Biology.2002; 47(23): 4155.

8. Hoshi Y, Yamada Y. Overview of diffuse optical tomography and its clinical applications. Journal of biomedical optics. 2016; 21(9):091312.

9. Wheelock MD, Culver JP, Eggebrecht AT. High-density diffuse optical tomography for imaging human brain function. Review of Scientific Instruments. 2019; 90(5):051101.

10. Chen J. Optical tomography in small animals with time-resolved Monte Carlo methods. Rensselaer Polytechnic Institute: New York, 2012.

11. Arridge SR, Schotland JC. Optical tomography: forward and inverse problems. Inverse problems.2009; 25(12):123010.

12. Karras DA, Reczko M, Mertzios V, Graveron-Demilly D, van Ormondt D, Papademetriou RC. Neural network reconstruction of MR images from noisy and sparse k-space samples. In WCC 2000-ICSP 2000. 2000 5th International Conference on Signal Processing Proceedings. 16th World Computer Congress 2000 2000 Aug 21 (Vol. 3, pp. 2115-2118). IEEE.

13. Kang E, Min J, Ye JC. A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction. Medical physics. 2017 Oct;44(10): e360-75.

14. Antholzer S, Haltmeier M, Schwab J. Deep learning for photoacoustic tomography from sparse data. Inverse problems in science and engineering. 2019 Jul 3;27(7):987-1005.

15. Perdios D, Besson A, Arditi M, Thiran JP. A deep learning approach to ultrasound image recovery. In2017 IEEE International Ultrasonics Symposium (IUS) 2017 Sep 6 (pp. 1-4). Ieee.

16. Ben Yedder H, Shokoufi M, Cardoen B, Golnaraghi F, Hamarneh G. Limited-angle diffuse optical tomography image reconstruction using deep learning. In International conference on medical image computing and computer-assisted intervention 2019 Oct 13 (pp. 66-74). Springer, Cham.

17. Jalalimanesh MH, Ansari MA. Deep learning based image reconstruction for sparse-view diffuse optical tomography. Waves in Random and Complex Media. 2021 Sep 14:1-7.

18. Lee RS, Gimenez F, Hoogi A, Miyake KK, Gorovoy M, Rubin DL. A curated mammography data set for use in computer-aided detection and diagnosis research. Scientific data. 2017 Dec 19;4(1):1-9.

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

19, Awsaf, CBIS-DDSM: Breast Cancer Image Dataset Version 1.2020. Available At: https://www.kaggle.com/awsaf49/cbis-ddsm-breast-cancer-image-dataset, 9/15/2020.

20. Al-Dhabyani W, Gomaa M, Khaled H, Fahmy A. Dataset of breast ultrasound images. Data in brief. 2020 Feb 1;28:104863.

21. Fang Q, Boas DA. Tetrahedral mesh generation from volumetric binary and grayscale images. In2009 IEEE international symposium on biomedical imaging: from nano to macro 2009 Jun 28 (pp. 1142-1145). Ieee.

22. Schweiger M, Arridge SR. The Toast++ software suite for forward and inverse modeling in optical tomography. Journal of biomedical optics. 2014 Apr;19(4):040801.

23, Sabir S, Cho S, Kim Y, Pua R, Heo D, Kim KH, Choi Y, Cho S. Convolutional neural network-based approach to estimate bulk optical properties in diffuse optical tomography. Applied Optics. 2020 Feb 10;59(5):1461-70.

24, Cao B, Zhang L, Shi K, Zhao Z, Sun Z, Li J, Zhou Z, Gao F. Optimization method of diffuse optical tomography reconstruction based on neural network. In Optics in Health Care and Biomedical Optics X 2020 Oct 10 (Vol. 11553, p. 1155328). International Society for Optics and Photonics.

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