

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

خلاصه

انیس میسمی^۱
محمدعلی انصاری^{۲*}

مقدمه: تصویربرداری پخش نوری یک تکنیک تصویربرداری غیرتهاجمی و غیرمخرب است که از امواج الکترومغناطیسی در محدوده طول موجی 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 سبب شده 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 حل این مسئله ارائه شده است.

روش بررسی: برای پیاده‌سازی این روش با استفاده از شبیه‌سازی رایانه‌ای، بافت‌هایی مکعبی شکل با ابعاد $64 \times 64 \times 64 \text{ mm}^3$ با تومورهایی در عمق ۲۱ تا ۴۲ میلی‌متری ایجاد گردید. برای اندازه‌گیری از مرز بافت، شبکه‌ای 5×5 از منابع و آشکارسازها در طرفین بافت تعبیه کردیم. برای انجام عمل بازسازی، دو شبکه عصبی ژرف با معماری کاملاً متصل و کانولوشنی دوبعدی ایجاد نمودیم.

یافته‌ها: برای سنجش کارایی این الگوریتم‌ها، عملکرد آنها را با یکی از روش‌های کلاسیک برپایه مدل یعنی روش گرادیان مزدوج مقایسه کردیم. برای مقایسه این روش‌ها از معیارهایی چون میانگین خطای مطلق (MAE)، خطای حداقل مربعات (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.

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 شهید بهشتی، تهران، ایران

نویسنده مسئول: محمدعلی انصاری

پست الکترونیکی:

m_ansari@sbu.ac.ir

۰۹۱۲۲۵۸۶۴۳۷

شماره تماس:

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

مقدمه

تصویربرداری زیستی یک تکنیک تصویربرداری غیرتهاجمی است که هدف آن، نمایان کردن فرآیندها و فعالیت‌های زیستی در یک دوره زمانی خاص است. این فرآیند هیچ‌گونه دخالتی بر روی فرآیندهای حیاتی مانند حرکت، تنفس و... نداشته و می‌تواند بدون دخالت فیزیکی، در دستیابی به اطلاعات گسترده‌ای از ساختار آناتومی نمونه‌ی مورد آزمایش گرفته تا غلظت مولکول‌های نشانگر زیستی کمک کند. در این فرآیند به‌طور معمول می‌توان از نور، فلورسانس، 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 موجی فروسرخ نزدیک (۷۰۰ تا ۱۱۰۰ 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 نادر بوده و در مرزهای بافت، بیشتر فوتون‌های پخش‌شده در آشکارسازها دریافت می‌گردد. بر همین اساس، در اوایل دهه ۱۹۹۰ میلادی الگوریتم‌هایی که از فوتون‌های پخش‌شده برای بازسازی تصاویر و در نهایت رسیدن به پارامترهای داخلی بافت همانند ضریب جذب و پراکندگی استفاده می‌کردند، پیشنهاد شد (۲-۴) اندازه‌گیری این پارامترهای نوری می‌تواند در دستیابی به اطلاعاتی در مورد عملکرد و ساختار بافت مفید باشد.

تصویربرداری به این روش در مقایسه با دیگر روش‌های تصویربرداری دارای مزایایی مانند کاهش ابعاد چینه‌آزمایشگاهی، 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 و ۶)، تصویربرداری از مغز نوزادان (۷)، تصویربرداری عملکردی^۱ از مغز بزرگسالان (۸ و ۹) 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 بر مبنای معادلات پخش مدل‌سازی شده، محاسبه گردیده و در مسئله

معکوس (بازسازی تصویر) به دنبال 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 خطی و غیرخطی متعددی جهت حل این مسئله ابداع شده‌اند. یکی از رایج‌ترین روش‌ها، روش غیرخطی بهینه‌سازی برپایه تکرار است. در این روش، توزیع خواص اپتیکی از طریق کمینه‌سازی مکرر تابع خطا بین داده‌های محاسباتی و داده‌های اندازه‌گیری شده، به مقادیر واقعی نزدیک گشته و در نهایت 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 بازسازی شده دقت و کیفیت محدودی دارند؛ بنابراین گسترش و کلینیکی شدن 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^۲ (۱۲)، تصویربرداری x-ray (۱۳)، فوتوآکوستیک^۳ (۱۴) و فراصوت^۴ (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 (۱۶ و ۱۷) و نشان داده شده 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 اولیه‌ای بهره نبرده و تنها با استفاده از مجموعه داده‌های بزرگ شروع به یادگیری ناشناخته‌ها کرده تا در نهایت مسئله معکوس را حل کنیم.

² Magnetic Resonance Imaging: MRI

³ Photoacoustic

⁴ Ultrasound

¹ Functional imaging

چهاروجهی یا تتراهدراست است. برای این که ببینیم این میزان چگالی مش بهینه است یا خیر، اندازه المان‌ها را کاهش دادیم تا مش چگال‌تر شود. مشاهده شد که با افزایش چگالی مش بیشتر از این مقدار، تغییرات قابل ملاحظه‌ای در حل 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 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 $1/01 \text{ mm}^{-1}$ و ضریب پراکندگی 1 mm^{-1} و ضریب شکست ۱/۴ هستند. محل قرارگیری تومورها در عرض و طول فانتوم تصادفی بوده و دارای ضرایب جذب ۰/۰۲، ۰/۰۴، ۰/۰۶، ۰/۰۸ بر میلی‌متر هستند. پس از حل مسئله مستقیم نويز تصادفی ۰/۰۱ درصد اضافه‌شده تا شرایط آزمایشگاهی را شبیه‌سازی کند. در نهایت دو خروجی از این مسئله به دست 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 در نظر گرفته شده این است که در مدل‌سازی مد پیوسته^۴ نمی‌توان از مسیر و زمان حرکت نور اطلاعی به دست آورد و قادر به بازسازی هم زمان ضرایب جذب و پراکندگی نیستیم.

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 پس زمینه $1/01 \text{ mm}^{-1}$ و با تک تومورهایی نامتقارن با ضرایب جذب ۰/۰۲، ۰/۰۴، ۰/۰۶ و ۰/۰۸ بر میلی‌متر ایجاد نمودیم. سپس به سراغ استفاده از شبکه‌های عصبی مصنوعی کاملاً متصل^۱ و کانولوشنی^۲ جهت بازسازی توزیع ضرایب جذب درونی رفتیم. در نهایت 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 گوگل دیتاست، کگل^۳ در نهایت به تصاویر بخش‌بندی‌شده تومور پستان دست یافتیم که به کمک روش‌های تصویربرداری ماموگرافی (۱۸ و ۱۹) و فراصوت (۲۰) به دست 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 سه‌بعدی 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 $64 \times 64 \times 64 \text{ mm}^3$ 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

¹ Fully Connected Neural Network: FCNN

² Convolutional Neural Network: CNN

³ Kaggle.com

⁴ Continuous wave

بازسازی تصاویر پخش نواری

بازسازی با روش غیرخطی گرادیان مزدوج (روش کلاسیک)

برای حل مسئله معکوس پخش از روش گرادیان مزدوج بهره گرفته و برای کاهش بدتعریفی مسئله از تابع تنظیم‌ساز تفاوت کامل^۱ 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 متصل و کانوولوشنی دوبعدی ایجاد نمودیم. هایپرپارامترهای آموزشی این روش مانند نرخ یادگیری و بهینه‌ساز، با روش جستجوی شبکه‌ای^۲ 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 مربعات و شاخص ارزیابی در هر دور (اپاک^۳)، خطای میانگین مطلق در نظر گرفته شد.

شبکه عصبی با لایه‌های کاملاً متصل:

برای آموزش این شبکه از ۱۰۰۰ دور آموزشی و اندازه دسته ۱۲۸ تکنیک توقف زودهنگام^۴ جهت جلوگیری از بیش‌برازش^۵ استفاده شده است. علاوه بر 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 در نظر گرفته شده است؛ بنابراین ۱۲۲۴۰ داده‌ی آموزشی، ۳۴۰۰ داده‌ی آزمایشی و ۱۳۶۰ داده‌ی ارزیاب داریم. داده‌های ورودی که همان اندازه‌گیری‌های مرزی ما هستند با لگاریتم‌گیری و نرمال‌سازی، استاندارد شده و روی داده‌های خروجی هیچ‌گونه پیش‌پردازشی صورت نگرفته است. در هر لایه تابع فعال‌ساز رلو^۶ به‌کار برده شده و برای بهبود

فرآیند یادگیری از بهینه‌ساز آدام^۷ با نرخ یادگیری ۰/۰۰۰۱ استفاده شده است. این شبکه با بهینه‌سازهای دیگری چون گرادیان کاهشی تصادفی نیز امتحان شد. نرخ یادگیری اولیه این شبکه ۰/۰۱ در نظر گرفته شد (با آزمون و خطا) و در طول هر اپاک (دور) به‌صورت نمایی کاهش می‌یافت، اما توانست 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 کانوولوشنی به همراه یک لایه کاملاً متصل 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 البته یکی از مزیت‌های این نوع شبکه است چرا که با کاهش پارامترهای آموزشی عملاً ویژگی‌های بدون اهمیت از مسئله خارج می‌شوند. در اینجا هم از همان تعداد داده آموزشی، آزمایشی و ارزیابی استفاده شده و تابع فعال‌ساز رلو به همراه بهینه‌ساز آدام با همان نرخ یادگیری به کار برده 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 گوگل کولب^۸ در اختیارمان گذاشته، استفاده کردیم.

معیارهای ارزیابی

عملکرد الگوریتم‌های ارائه شده توسط روش‌های کلاسیک و یادگیری ژرف توسط معیارهایی چون میانگین خطای مطلق^۹، خطای حداقل مربعات^{۱۰}، بیشینه‌ی سیگنال به نویز^{۱۱} و شاخص شباهت ساختاری^{۱۲} ارزیابی می‌شود. این پارامترها به‌صورت زیر تعریف می‌شوند:

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

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

^۹ Mean Absolute Error: MAE

^{۱۰} Mean Squared Error: MSE

^{۱۱} Peak Signal to Noise Ratio: PSNR

^{۱۲} Structural Similarity Index Metric: SSIM

^۱ Total Variation

^۲ Grid search

^۳ Epoch

^۴ Early stopping

^۵ Overfitting

^۶ ReLU

نسبت به گرادیان مزدوج در همه معیارها عملکرد بهتری از خود نشان دادند. به طور مثال در فانتومی که مقطعی از آن در بخش سمت چپ شکل ۴ نشان داده شده و دارای توموری با ضریب جذب 0.02 بر میلی متر است، شبکه کاملاً متصل و کانولوشنی توانسته اند MSE را به ترتیب 84% و 62% ، MAE را 76% و 69% PSNR را تقریباً ۲ برابر کند. نتایج به دست آمده نشان داد که MSE به صورت میانگین 86% درصد و MAE تا 81% درصد کاهش داشته و PSNR ۲ برابر افزایش یافته است.

بحث و نتیجه گیری

تصویربرداری پخش نوری یک تکنیک تصویربرداری غیرتهاجمی و غیرمخرب است که ظرفیت زیادی در تصویربرداری از بافت های زیستی چون سینه و مغز دارد. عواملی چون پراکندگی بسیار زیاد نور در بافت های زیستی و تعداد محدود اندازه گیری ها سبب شده مسئله بازسازی تصویر در این تکنیک چالش برانگیز شود. الگوریتم های خطی و غیرخطی متعددی جهت حل این مسئله ابداع شده اند اما هریک از ضعف هایی چون محاسبات سنگین و نیاز به فضای ذخیره سازی بزرگ و صرف زمان طولانی رنج برده و تصاویر بازسازی شده دقت و کیفیت محدودی دارند. در این پژوهش، روشی جدید بر پایه یادگیری ژرف برای حل این مسئله ارائه شده است. این روش به جای وابستگی به فیزیک مسئله، الگوهای موجود در داده های مسئله مستقیم پخش را یافته و براساس این الگوها توزیع ضرایب اپتیکی درون بافت را پیش بینی می کند.

برای پیاده سازی این روش ما نیازمند تعداد زیادی داده جهت آموزش الگوریتم های آن هستیم. از آنجاکه این تکنیک تصویربرداری دارای مجموعه داده قابل دسترسی نیست باید در قدم اول تعداد زیادی بافت مصنوعی با توزیع های اپتیکی مختلف تولید کرده و با ایجاد یک سیستم تصویربرداری، شدت نور پخش شده از مرز آنها را دریافت نماییم. بدین منظور، با استفاده از شبیه سازی رایانه ای، بافت هایی مکعبی شکل با ابعاد $64 \times 64 \times 64 \text{ mm}^3$ با تومورهایی در عمق ۲۱ تا ۴۲ میلی متری ایجاد گردید. شکل این تومورها از تصاویر ماموگرافی و فراصوت دریافت شده است و هر بافت تنها یک تومور دارد. برای اندازه گیری از مرز بافت، شبکه ای 5×5 از منابع و آشکارسازها در طرفین بافت تعبیه کردیم. در مجموع ۶۲۵ اندازه گیری انجام گرفت که برای شبیه سازی شرایط

$$PSNR = 10 \log_{10} \left\{ \frac{[\max(x_{recon})]^2}{MSE} \right\} \quad (3)$$

$$SSIM = \frac{(2\bar{x}_{true}\bar{x}_{recon}+c_1)(2\sigma_{true.recon}+c_2)}{(\bar{x}_{true}^2+\bar{x}_{recon}^2+c_1)(\sigma_{true}^2+\sigma_{recon}^2+c_2)} \quad (4)$$

که در آن x_{recon} و x_{true} به ترتیب ضریب جذب واقعی و بازسازی شده و $\bar{x}_p$ (p=recon یا true) میانگین و انحراف معیار داده های واقعی و بازسازی شده هستند. $\sigma_{true.recon}$ کواریانس (هموردایی) بین داده های واقعی و بازسازی شده و c_1 و c_2 ثوابت پایداری مسئله هستند. میانگین خطای مطلق و خطای حداقل مربعات برای مقایسه دقت تصویر بازسازی شده به کار می روند. بیشینه سیگنال به نویز با واحد دسی بل نسبتی است بین بیشینه توان یک تصویر و بیشینه نویزی که تصویر را تحت تاثیر قرار می دهد. هرچه قدر مقدار آن بیشتر باشد یعنی توانایی بازسازی تصویر بیشتر است. شاخص شباهت ساختاری نیز شباهت بین تصویر واقعی و بازسازی شده را نشان می دهد و هرچه که به یک نزدیکتر باشد یعنی تصویر ایده آل تر است. یک بازسازی خوب شامل MAE و MSE کم و PSNR و SSIM بزرگ است.

یافته ها

عملکرد شبکه های عصبی ایجاد شده بر روی داده های آموزشی و آزمایشی در جدول ۳ آمده است. این جدول نشان می دهد که اندازه خطای آموزشی و آزمایشی در هر دو شبکه بسیار به هم نزدیک بوده و شبکه های ما دچار بیش برآزش نشده است؛ بنابراین عمل یادگیری توسط این الگوریتم ها به درستی انجام شده است. آموزش هر دو شبکه کمتر از ۱ ساعت زمان برده است.


برای سنجش کارایی روش های یادگیری ژرف در بازسازی تصاویر حاصل از پخش نوری، تفاوت شاخص های کیفیت تصویر بازسازی شده توسط این روش و روش های کلاسیک گرادیان مزدوج در جدول ۴ بیان شده و سه نمونه تصویر بازسازی شده که دارای تومورهایی با ضرایب جذب 0.02 ، 0.04 و 0.06 بر میلی متر هستند در شکل ۴ نشان داده شده است. بازسازی تصویر به روش گرادیان مزدوج ۳۵۰۰ ثانیه به طول انجامیده است که یکی از دلایل همگرایی آهسته این روش است.

همان طور که از جدول ۴ پیداست، شبکه های عصبی ژرف

که وارد کردن الگوریتم‌های هوش مصنوعی به این تکنیک تصویربرداری در مقایسه با روش‌های بهینه‌سازی معمول، باعث کاهش زمان بازسازی و افزایش دقت آن شده است. از جمله چالش‌های ما در این پژوهش این بود که کار ما در دسته نگاشت مستقیم^۱ قرار می‌گیرد بدین معنی که یک نگاشت کامل یا جزئی از داده‌های اندازه‌گیری شده 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 تنظیم‌سازی داده محور استفاده کرده و این گونه 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 فناوریان کشور (INSF) برگرفته از طرح شماره (۹۸۰۲۹۴۶۰) انجام شده است.






آزمایشگاه، با نویز ۱ درصد تصادفی همراه شد. داده‌های اندازه‌گیری شده نویزدار به عنوان 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 متصل و کانولوشنی دوبعدی ایجاد نمودیم. خطای آموزشی هر دو شبکه، خطای میانگین مربعات و شاخص ارزیابی در هر دور (اپاک)، خطای میانگین مطلق در نظر 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 کانولوشنی 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 اما سرعت همگرایی آن کم است. حل مسئله معکوس به این روش برای هر یک از نمونه‌ها دست‌کم ۳۵۰۰ ثانیه به طول می‌انجامد، این در حالی است که بازسازی تصویر به کمک شبکه‌های عصبی ژرف تنها ۲ تا ۳ ثانیه به طول می‌انجامد. علاوه بر 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 از جمله، تعداد بیشتر نمونه‌ها، سه‌بعدی بودن نمونه‌ها و شکل نامتقارن تومورهای آنهاست. از آنجاکه بسیاری از تلاش‌های صورت گرفته بر روی نمونه‌هایی دوبعدی با تومورهای متقارن دایره‌ای شکل هستند و چیدمان منابع و آشکارسازها به صورت ۱۶*۱۶ پیرامون بافت قرار دارد، در این پژوهش به سراغ دیگر شکل‌های بافت رفتیم و چیدمانی متراکم‌تر را در نظر گرفتیم به همین دلیل 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 دسترس بودن تعداد بسیار اندکی از اندازه‌گیری‌های پخش نوری در مقایسه با سایر روش‌های تصویربرداری مانند ام‌آر‌آی و سی تی اسکن در نوع خود قابل توجه است. مقایسه نتایج نشان داد


¹ Direct mapping



شکل ۴: تصاویر واقعی و بازسازی شده توسط روش گرادیان مزدوج، شبکه کاملاً متصل و کانولوشنی در $Z=25$



شکل ۲: الف) نمای کلی از سطح مش، ب) نمای از درون مش تولیدی



شکل ۳: نمای از آرایش منابع و آشکارسازها

جدول ۳ خطای شبکه کاملاً متصل و کانوولوشنی

نوع داده	خطای حداقل مربعات		خطای مطلق
آموزشی	شبکه کاملاً 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

جدول ۴ مقایسه شاخص‌های کیفیت تصویر در سه روش گرادیان مزدوج و شبکه‌های عصبی کاملاً متصل و کانوولوشنی

روش	ضریب جذب mm^{-1}	MSE	MAE	PSNR (dB)	SSIM
شبکه کاملاً متصل	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 متصل	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 متصل	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

جدول ۱ معماری شبکه کاملاً متصل

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	

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 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. In *2017 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.

- 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. In 2009 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.