



ارائه‌ی یک مدل برای تبدیل MRI ساختاری به CT در ناحیه مغز با یادگیری ادراکی در شبکه‌های مولد متخاصم

مریم نصر آزادانی^۱، محمدرضا یزدچی^۲

^۱ دانشگاه اصفهان، دانشکده فنی و مهندسی، گروه مهندسی پزشکی

maryam.nasr@eng.ui.ac.ir

^۲ دانشگاه اصفهان، دانشکده فنی و مهندسی، گروه مهندسی پزشکی

yazdchi@eng.ui.ac.ir

یک موقعیت آناتومی را نشان نمی‌دهند. این عدم انطباق می‌تواند به دلیل اختلاف در حالت بدن^۱ بیمار در حین تصویربرداری، حرکت‌های فیزیولوژی (مثل تنفس یا تپش قلب) و یا تغییرات فیزیولوژی و پاتولوژی (مثل رشد تومور) باشد. در فرایند معمول طراحی درمان، در مرحله نخست MRI و CT منطبق می‌شوند تا این اختلافات تا حد ممکن جبران شود. سپس مرز بافت‌ها از تصویر MRI مشخص و به CT منتقل می‌شود. در نهایت دوز روی تصویر CT محاسبه می‌شود.

یکی از مهم‌ترین چالش‌های این نوع طراحی، انطباق تصاویر است. این الگوریتم، هرچه قدر هم دقیق عمل کند، در مورد خروجی آن عدم قطعیت وجود دارد. به بیان دیگر نمی‌توان مطمئن بود محلی که در تصویر CT برای تومور فرض شده است، دقیقاً منطبق بر محل اصلی تومور است. برای رفع این عدم قطعیت، می‌توان طراحی درمان را به صورت مستقیم روی تصویر MRI انجام داد. به این منظور لازم است الگوریتمی طراحی شود که تصویر CT را از تصویر MRI محاسبه کند. به این ترتیب فقط با داشتن MRI می‌توان طراحی درمان را تکمیل کرد. در صورت پیاده‌سازی این الگوریتم، علاوه بر رفع نیاز به انطباق، میزان دوز دریافتی بیمار، هزینه و زمان درمان کمتر می‌شود. در ادامه به بررسی پژوهش‌های پیشین در این حوزه پرداخته می‌شود.

نخستین روش‌های موجود برای تبدیل MRI به CT مبتنی بر بخش‌بندی^۲ و تصاویر اطلس^۳ بوده‌اند. ولی این روش‌ها زمان‌بر هستند و کیفیت تصاویر خروجی برای استفاده در کاربردهای بالینی مناسب نیست [۱].

چکیده- طراحی درمان مبتنی بر تصویر MRI، روشی است که بدون نیاز به تصویر CT برنامه پرتودرمانی مشخص می‌شود. این روش سبب کاهش دوز دریافتی و هزینه و تسریع درمان می‌شود. از مهم‌ترین مراحل طراحی این روش، ایجاد تصویر CT از تصویر MRI است. در این پژوهش الگوریتمی بر اساس شبکه‌های مولد متخاصم، برای تبدیل MRI به CT معرفی می‌شود. برای آموزش از ۲۴ جفت تصویر سه‌بعدی استفاده شده است. تصاویر MRI از نماهای T1، T2 و PD هستند. شبکه بر مبنای Pix2Pix پیاده‌سازی شده است؛ ولی معماری شبکه مولد به ResNet تغییر داده شده است. برای یادگیری بهتر تابع اتلاف ادراکی به تابع اتلاف اصلی اضافه شده است. مدل پیشنهادی MAE ۰.۹/۱۸، PSNR ۲۲/۸۰ و SSIM ۰.۸۲۹۷/۰ دارد.

کلمات کلیدی- تبدیل MRI به CT، CT ساختگی، تابع اتلاف ادراکی، Pix2Pix.

۱. مقدمه

طراحی درمان فرایندی است که تنظیمات مناسب برای عملیات پرتودرمانی یک بیمار را مشخص می‌کند. یک طراحی خوب می‌تواند تضمین کند که تومور بیشترین و بافت سالم کمترین میزان ممکن پرتوایکس را دریافت کند. محاسبه دوز دریافتی در هر نقطه از بدن، نیازمند تصویر CT است. ولی در تصویر CT جزئیات بافت نرم مشخص نیست و نمی‌توان مرز بافت سالم و تومور را تفکیک کرد. در مقابل تصویر MRI بافت نرم را با کنتراست بالایی نشان می‌دهد ولی به صورت مستقیم نمی‌تواند در محاسبه دوز استفاده شود؛ بنابراین اطلاعات تصاویر CT و MRI به صورت مکمل در محاسبه دوز مورد نیاز است. اما تصاویر MRI و CT کاملاً بر هم منطبق نیستند؛ یعنی پیکسل‌های مشابه از دو تصویر، دقیقاً

³ Atlas Based

¹ Posture

² Segmentation Based



در سال ۲۰۱۸، امامی و همکاران [۶] از یک شبکه GAN برای تبدیل تصاویر MRI با وزن T1 پس از تزریق ماده حاجب، در ناحیه مجمله و مغز، به تصویر CT معادل استفاده کرده‌اند. شبکه مولد بر اساس ResNet است. شبکه‌ی جداکننده شامل ۵ لایه‌ی کانولوشنی است و با دریافت تصویر در ورودی، مشخص می‌کند که اصل یا ساختگی است. تابع اتلاف خصمانه، بر اساس حداقل مربعات^۹ خطا و قدر مطلق اختلاف تصویر ساختگی و تصویر اصلی در نظر گرفته شده است. این روش نسبت به حالتی که از ResNet خارج از ساختار GAN، فقط به‌عنوان یک مولد برای تبدیل تصویر استفاده شده، تصاویر CT با نمای بصری بهتری داشته است.

تا اینجا روش‌های معرفی شد که به‌صورت نظارتی^{۱۰} تصاویر را تبدیل می‌کردند؛ یعنی برای یادگیری، نیاز به داده‌های جفت و منطبق است. در سال ۲۰۱۷، نخستین بار در [۷] از شبکه‌های خصمانه مبتنی بر حلقه^{۱۱} برای تبدیل بدون نظارت^{۱۲} تصاویر پزشکی استفاده شده است. این شبکه‌ها، برای یادگیری، نیازمند تابع اتلاfi هستند که تضمین کند تصویر به‌دست‌آمده، از نظر آناتومی، مشابه تصویر ورودی است [۸]. به‌صورت کلی روش‌های نظارتی نسبت به روش‌های بدون نظارت نتایج قابل‌اطمینان‌تر دارند؛ پس اگر داده‌ها جفت و منطبق باشد، بهتر است از روش‌های نظارتی استفاده شود [۹]. داده‌های جفت، برای هدف این پژوهش، یعنی تبدیل MRI به CT در ناحیه مغز، موجود است. همچنین در این ناحیه تغییرات فیزیولوژی کم است و بخش اصلی اختلاف، با عملیات انطباق خطی^{۱۳} قابل جبران است. به همین دلیل در این پژوهش از روش‌های نظارتی استفاده می‌شود.

تابع اتلاف نقش مهمی در یادگیری شبکه دارد و مشخص می‌کند تصویر خروجی چه شاخص‌هایی را داشته باشد. در سال ۲۰۱۶، با هدف در نظر گرفتن ویژگی‌های تصاویر در فرایند یادگیری، تابع اتلاف ادراکی^{۱۴} معرفی شده است [۱۰]. این تابع ویژگی‌ها را از خروجی لایه‌های داخلی یک شبکه دسته‌بندی محاسبه می‌کند. در سال ۲۰۲۰، از این تابع برای تبدیل تصاویر پزشکی (تبدیل PET به CT و رفع نویز MRI) [۱۱] و در سال ۲۰۲۲ برای تبدیل تصویر MRI به CT ناحیه‌ی لگن استفاده شده است [۱۲].

امروزه با گسترش هوش مصنوعی و مطرح‌شدن معماری‌های جدید از شبکه‌های یادگیری، می‌توان امیدوار بود که تصاویر شبه‌واقعی CT جایگزین تصویربرداری فیزیکی در پرتودرمانی شود (منظور از تصویر شبه‌واقعی آن است که تصویر ساختگی آن قدر به تصاویر واقعی CT نزدیک باشد که کاربر انسانی برای تشخیص جعلی بودن آن با چالش مواجه شود).

نخستین بار در سال ۲۰۱۶ از یادگیری برای تبدیل تصویر MRI به CT استفاده کرده‌اند [۲]. شبکه پیشنهادی شامل سه لایه کانولوشنی بوده و تصاویر را با استخراج قطعه‌های سه‌بعدی کوچک از تصویر اصلی تبدیل می‌کند. الگوریتم پیشنهادی نسبت به روش‌های مبتنی بر اطلس نتایج و سرعت بهتری داشته است. سال ۲۰۱۷ نخستین شبکه یادگیری عمیق برای تبدیل تصویر MRI به CT پیشنهاد شده است [۳]. در این پژوهش به کمک یک مدل مبتنی بر UNet، تصاویر دوبعدی MRI را به CT تبدیل شد. این روش از اطلاعات کل برش^۱ MRI برای تشکیل تصویر CT استفاده می‌کند و تصویر نهایی پیوستگی بیشتری دارد.

اساس تابع اتلاف^۳ در این مدل‌ها اختلاف پیکسل با پیکسل بین تصویر CT مرجع و CT ساختگی است. این تابع اتلاف سبب می‌شود شبکه تصاویری ایجاد کند که نسبت به تصویر واقعی تارشدگی دارند. برای رفع این مشکل لازم است به تابع اتلاف بخشی اضافه شود که تضمین کند تصویر خروجی به تصاویر واقعی شبیه است و در توزیع آماری تصاویر CT قرار می‌گیرد. به این منظور می‌توان از شبکه‌های مولد متخاصم^۴ (GAN) بهره برد. این معماری با یادگیری هم‌زمان دو شبکه مولد^۵ و جداکننده^۶، می‌تواند تصاویر بسیار شبه‌واقعی ایجاد کند. در طی آموزش، شبکه جداکننده یاد می‌گیرد تا بهتر بتواند تصاویر جعلی مولد را شناسایی کند و شبکه مولد یاد می‌گیرد تصاویر واقعی‌تر ایجاد کند تا شبکه جداکننده نتواند جعلی بودن آن را تشخیص دهد. نخستین بار سال ۲۰۱۷ ایده‌ی استفاده از شبکه‌های GAN برای تبدیل تصویر MRI به CT مطرح شده است [۴]. این روش بهبود داده شده و در سال ۲۰۱۸ نتایج نهایی ارائه شده است [۵]. تابع اتلاف این شبکه براساس گرادیان تصویر ساختگی با تصویر اصلی در کنار تابع اتلاف خصمانه^۷ است. PSNR این روش ۲۷/۶ شده است (در مقایسه با ۲۴/۷ برای ساختار غیر خصمانه^۸).

⁸ Non Adversarial

⁹ Least Square

¹⁰ Supervised

¹¹ Cycle GAN

¹² Unsupervised

¹³ Rigid Registration

¹⁴ Perceptual Loss Function

¹ Patch

² Slice

³ Loss Function

⁴ Generative Adversarial Network

⁵ Generator

⁶ Discriminator

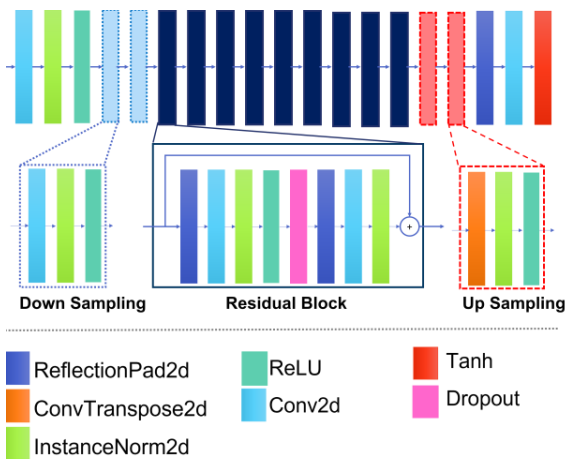
⁷ Adversarial Loss Function

در پایان دو بیمار به صورت تصادفی برای آزمایش^۷، یک بیمار برای اعتبارسنجی^۸ و پنج بیمار باقی‌مانده برای آموزش^۹ انتخاب شدند. با این روش تقسیم‌بندی می‌توان اطمینان داشت هیچ دو تصویر متفاوت از یک بیمار در آموزش و آزمایش وجود ندارد. به بیان دیگر شبکه در حین آموزش هیچ داده‌ی مشابه با تصاویر آزمایش را مشاهده نمی‌کند.

۲-۳ ساختار شبکه

مبنای این پژوهش، شبکه‌ی Pix2Pix است [۱۴]. این شبکه در سال ۲۰۱۷ با هدف تبدیل نظارتی تصاویر معرفی شد. Pix2Pix در اصل یک شبکه مولد متخاصم با مولد UNet است. شبکه جداکننده شامل سه مجموعه لایه‌ی کانولوشنی است و بررسی می‌کند که آیا هر قطعه از تصویر ساخته‌شده، و نه کل تصویر، به تصاویر واقعی نزدیک است یا خیر. این جداکننده PatchGAN نامیده می‌شود و مزیت اصلی Pix2Pix نسبت به شبکه‌های تخصصی معمول است.

بر اساس پژوهش‌های پیشین اگر شبکه‌ی تبدیل به تصویر بر اساس ساختار ResNet باشد، تصویر ساخته‌شده شباهت بیشتری با تصویر مرجع دارد [۸]. از این رو در این پژوهش از یک شبکه مبتنی بر بلوک‌های Residual به عنوان مولد استفاده شد. به طور دقیق‌تر ساختار شبکه مولد در شکل ۱ آمده است. شبکه جداکننده، مشابه Pix2Pix اصلی، PatchGAN است.



شکل ۱: معماری شبکه مولد. این شبکه مبتنی بر ResNet است.

روش‌های تبدیل تصویر MRI به CT، به طور معمول با یک نما^۱ از MRI آموزش داده شده‌اند. برخی نیازمند تصاویر غیرمتداول MRI و یا تصاویر چند نما هستند [۸].

در این پژوهش شبکه‌ای برای تبدیل تصاویر پزشکی پیشنهاد می‌شود که با دریافت یک تصویر MRI ساختاری از نماهای متداول (وزن‌های T1، T2 و PD) بتواند تصویر CT را محاسبه کند. مدل مورد استفاده، بر مبنای شبکه‌های مولد متخاصم است. با اضافه کردن، تابع اتلاف ادراکی به شبکه مولد، تلاش می‌شود که در خروجی تصاویر CT شبه‌واقعی و مطابق با ساختار آناتومی تصویر MRI ورودی به دست آید.

۲. روش تهیه مقاله

در این بخش مراحل پیشبرد پژوهش بررسی می‌شود. ابتدا اطلاعات پایگاه داده و الگوریتم‌های پیش‌پردازش مطرح می‌شود. در ادامه معماری و ساختار مدل پیشنهادی تشریح می‌گردد.

۲-۱ داده

در این پژوهش از یک پایگاه داده عمومی استفاده شد [۱۳]. این پایگاه شامل تصاویر سه‌بعدی ۸ بیمار و به ازای هر بیمار ۱ تصویر CT و ۳ تصویر MRI با نماهای T1، T2 و PD است. در مجموع ۲۴ جفت تصویر CT-MRI موجود است.

۲-۲ پیش‌پردازش

در مرحله نخست تصاویر باید به صورت خطی^۲ و سپس غیرخطی^۳ منطبق شوند. به این منظور از کتابخانه ITK استفاده شد. معیار شباهت انطباق، اطلاعات متقابل بود. در ادامه واریانس داخلی هر تصویر MRI با الگوریتم N4 برای تصحیح میدان بیاس^۴ از کتابخانه ITK رفع شد. سپس تصاویر در بازه ۰ - ۲۵۵ معیار^۵ شدند. در مرحله بعد ماسک تصویر MRI (موقعیت بافت بدن نسبت به پس‌زمینه) استخراج و در تصویر CT ضرب شد تا اجزای غیر آناتومی (مانند تخت تصویربرداری) از CT حذف شود.

تا اینجا تصاویر به صورت سه‌بعدی آماده شدند. در گام بعد تصاویر در برش‌های دوبعدی مقطعی^۶ ذخیره شدند تا با ورودی شبکه سازگار باشند. سپس برش‌هایی که شامل یک تصویر کامل از بافت نبودند حذف شدند. در نهایت ۵۴۸ جفت تصویر دوبعدی به دست آمد.

⁶ Axial

⁷ Test

⁸ Validation

⁹ Train

¹ Modality

² Rigid

³ Deformable

⁴ Bias Field Correction

⁵ Normalize

در نهایت شبکه مولد بر اساس تابع اتلاف رابطه ۵ آموزش دید.

$$L_G = L_{Gan} + \gamma_l L_{L1} + \gamma_p L_{perc} \quad (5)$$

γ_p و γ_l ابرپارامتر هستند و باید پیش از یادگیری تنظیم^۴ شوند.


الگوریتم پیشنهادی با کتابخانه pyTorch پیاده‌سازی شد. ساختار اصلی کد برمبنای [۱۵] بود و متناسب با روش پیشنهادی تغییر کرد. یادگیری در طی ۲۰۰ مرحله^۵ انجام شد. (۱۰۰ مرحله با نرخ یادگیری ثابت و در طول ۱۰۰ مرحله با نرخ یادگیری کاهشده). نرخ یادگیری اولیه برای هر دو مدل مولد و جداکننده ۰/۰۰۰۲ بود. اندازه‌ی دسته^۶ برای هر مرحله آموزش برابر ۴ در نظر گرفته شد. هر آموزش ۴ ساعت زمان برد (NVIDIA GeForce RTX 3060). زمان آزمایش برای یک برش دوعبده ۰/۱۵ ثانیه بود.

۳. نتیجه‌گیری

در این بخش نتایج به‌دست‌آمده در پژوهش بررسی می‌شود.

۳-۱ نتایج

برخی از نتایج برای هر نمای تصویر MRI در شکل ۱ آمده است.



شکل ۲: نمونه‌ای از تصاویر به‌دست‌آمده برای MRI با نمای T1, T2 و PD (از بالا به پایین). الف، تصویر MRI، ب، تصویر CT اصل و ج تصویر CT ساخته‌شده توسط مدل پیشنهادی است.

یکی از چالش‌های اصلی در آموزش شبکه‌های GAN، توقف یادگیری است؛ یعنی شبکه مولد پیوسته یک داده واقعی ولی ثابت را تولید کند. یا شبکه‌ی جداکننده آن قدر قوی عمل کند که به‌راحتی داده‌های جعلی مولد را تشخیص دهد. به‌این ترتیب گرادینان تابع اتلاف صفر و در نتیجه یادگیری متوقف می‌شود. دیده‌شده است که اگر توابع اتلاف مولد و جداکننده بر اساس روابط ۱ و ۲ باشد (تابع اتلاف حداقل مربعات)، احتمال توقف یادگیری کم می‌شود. این روابط مبنای توابع اتلاف در پژوهش حاضر هستند.

$$L_D = \frac{1}{2} E_{xy}[(D(y, x) - 1)^2] + \frac{1}{2} E_{xy}[(D(G(x), x))^2] \quad (1)$$

$$L_{GAN} = E_{xy}[(D(G(x), x) - 1)^2] \quad (2)$$

در این روابط x تصویر MRI، y تصویر CT اصل، $G(x)$ تصویر CT ساختگی و $D(y, x)$ تشخیص شبکه‌ی جداکننده روی تصاویر x و y است $E_{xy}[A]$ عملگر میانگین روی ماتریس A است.

برای تضمین شباهت آناتومی بین تصویر ساخته‌شده و تصویر مرجع، اختلاف این دو تصویر به‌عنوان خطا محاسبه شد. سپس نرم اول^۱ این خطا (رابطه ۳) به تابع اتلاف اضافه شد تا طی یادگیری کمینه شود. این تابع اتلاف در Pix2Pix اصلی نیز هست.

$$L_{L1} = E_{xy}[\|y - G(x)\|_1] \quad (3)$$

$\|A\|_1$ عملگر نرم اول ماتریس A است.

تابع اتلاف رابطه ۳ بررسی می‌کند که اختلاف پیکسلی تصویر ساختگی با تصویر اصلی کمینه مقدار ممکن باشد. ناظر انسانی نمی‌تواند این اختلاف پیکسلی را تشخیص دهد. در عوض با مقایسه‌ی ویژگی‌های دو تصویر، تفاوت‌ها را تشخیص می‌دهد. مشارکت این اختلاف ویژگی‌ها در تابع اتلاف می‌تواند سبب یادگیری بهتر مدل شود. به این منظور می‌توان تابع اتلاف ادراکی را نیز در یادگیری مدل مشارکت داد. تابع اتلاف ادراکی نیازمند مدلی برای استخراج ویژگی از تصاویر است. به این منظور از اطلاعات لایه‌های داخلی شبکه‌ی جداکننده استفاده می‌شود. تابع اتلاف ادراکی از رابطه ۴ به دست می‌آید.

$$L_{perc} = \sum_{i=0}^L (\gamma_{pi} P_i(G(x), y)) \quad (4)$$

$$P_i(\hat{x}, y) = \frac{1}{h_i w_i d_i} \|D_i(G(x), x) - D_i(y, x)\|_1$$

در این رابطه L تعداد لایه‌های درونی شبکه جداکننده و γ_{pi} ابرپارامتری قابل تنظیم $D_i(\hat{x}, x)$ خروجی و w_i, h_i, d_i به ترتیب ارتفاع، عرض و عمق لایه‌ی i ام شبکه‌ی جداکننده هستند.

⁴ Epoch

⁵ Batch Size

¹ L1 Norm

² Hyper-Parameter

³ Tune

در ادامه روش پیشنهادی با نتایج [۶] مقایسه شد (جدول ۲). ناحیه آناتومی موردبررسی در این پژوهش مشابه پژوهش حاضر است و اطلاعات لازم برای یکسان کردن شرایط ارزیابی (به‌عنوان مثال بازه مقادیر تصویر CT ساخته‌شده)، از مقاله قابل‌دسترس است. مشاهده می‌شود که الگوریتم پیشنهادی PSNR و SSIM نزدیک به روش [۶] دارد. ولی MAE، با اختلاف، کمتر است.

جدول ۲: مقایسه MAE، PSNR و SSIM برای [۶] و روش پیشنهادی


SSIM	PSNR	MAE	
۰/۸۳۲۰	۲۶/۶۴	۸۹/۳۰	[۶]
۰/۸۲۹۷	۲۲/۸۰	۱۸/۰۹	روش پیشنهادی

۳-۲- بحث

در این پژوهش روشی بر پایه شبکه‌های مولد متخاصم، برای تبدیل نظارتی تصاویر دوبعدی MRI ناحیه مغز به تصویر CT متناظر معرفی شد. برای تبدیل یک تصویر سه‌بعدی، می‌توان آن را به برش‌های مقطعی تقسیم کرد. سپس این برش‌های دوبعدی به CT تبدیل شود. در ادامه با اتصال برش‌های دوبعدی ساخته‌شده، تصویر سه‌بعدی CT به دست می‌آید. با این الگوریتم در کمتر از ۱۰ ثانیه، می‌توان از برش‌های دوبعدی MRI، تصاویر CT را ایجاد کرد. این زمان برای استفاده در نرم‌افزارهای بالینی مناسب است. تصاویر پزشکی معمولاً به‌صورت دوبعدی و با فرمت DICOM ذخیره می‌شوند و با ورودی شبکه سازگار هستند.

روش‌های پیش‌ازاین معمولاً محدود به یک نمای خاص از تصاویر MRI بودند. به‌عنوان مثال در [۶] (مرجع مقایسه در بخش نتایج)، فقط برای MRI-T1 با تزریق ماده حاجب آموزش داده‌شده است. در برخی از الگوریتم‌ها به تصویر MRI در چند نما نیاز است. [۱۶]، به تصاویر T1 قبل و بعد از تزریق ماده حاجب و T2 نیاز دارد تا بتواند تصویر CT را محاسبه کند. پس فقط در صورت موجود بودن تمامی این تصاویر قابل‌استفاده است. برخی از روش‌ها به ناهای غیرمتداول از MRI نیاز دارند. به‌عنوان مثال [۱۷]، بر اساس نمای UTE عمل می‌کند. در این نما بافت استخوان بهتر مشخص است. ولی نسبت به سایر تصویربرداری‌های MRI، زمان‌بر است و کاربرد بالینی کم‌تری دارد؛ یعنی لازم است تصویربرداری طولانی‌مدتی انجام شود که معمولاً جز تبدیل تصویر، کاربرد دیگری ندارد. هر تصویربرداری‌های اضافه سبب افزایش هزینه، به تأخیر افتادن درمان و فشار روانی به بیمار می‌شود.

در ادامه ساختار شبکه مولد و تأثیر آن در تصویر ساختگی بررسی شد. در شکل ۲ نمونه‌ای از تصویری که توسط مولد UNet و ResNet ساخته‌شده مشاهده می‌شود.



شکل ۳: بررسی تأثیر معماری شبکه مولد. الف، تصویر MRI، ب تصویر CT اصل، ج و د به ترتیب CT ساخته‌شده توسط مولد UNet و ResNet هستند.

الگوریتم پیشنهادی با معیارهای MAE، PSNR و SSIM ارزیابی شد. به‌منظور بررسی دقیق الگوریتم پیشنهادی، اعتبارسنجی متقابل چهار برابری^۱ انجام شد؛ یعنی کل داده‌ها (شامل ۸ بیمار - هر بیمار ۳ تصویر) به ۴ بخش (۲ بیمار در هر بخش) تقسیم شد. در هر مرحله الگوریتم روی ۳ بخش آموزش داده و روی بخش چهارم ارزیابی شد. نتایج کمی این ۴ مرحله در جدول ۱ آمده است.

جدول ۱: محاسبه MAE، PSNR و SSIM بین تصاویر CT اصل و تصویر CT ساخته‌شده توسط الگوریتم پیشنهادی

SSIM	PSNR	MAE	
۰/۸۳۵۲	۲۲/۶۷	۱۶/۷۹	ارزیابی ۱
۰/۸۳۰۶	۲۴/۱۷	۱۵/۸۷	ارزیابی ۲
۰/۸۱۸۱	۲۳/۵۳	۱۸/۰۴	ارزیابی ۳
۰/۸۳۵۰	۲۰/۶۸	۲۱/۶۵	ارزیابی ۴
۰/۸۲۹۷	۲۲/۸۰	۱۸/۰۹	میانگین
۰/۰۰۷	۱/۳	۲/۲	انحراف معیار

^۱ 4Fold Cross Validation



- [3] X. Han, "MR-based synthetic CT generation using a deep convolutional neural network method," (in eng), *Med Phys*, vol. 44, no. 4, pp. 1408-1419, Apr 2017, doi: 10.1002/mp.12155.
- [4] D. Nie *et al.*, "Medical Image Synthesis with Context-Aware Generative Adversarial Networks," (in eng), *Med Image Comput Comput Assist Interv*, vol. 10435, pp. 417-425, Sep 2017, doi: 10.1007/978-3-319-66179-7_48.
- [5] D. Nie *et al.*, "Medical Image Synthesis with Deep Convolutional Adversarial Networks," *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 12, pp. 2720-2730, 2018, doi: 10.1109/TBME.2018.2814538.
- [6] H. Emami, M. Dong, S. P. Nejad-Davarani, and C. K. Glide-Hurst, "Generating synthetic CTs from magnetic resonance images using generative adversarial networks," (in eng), *Med Phys*, Jun 14 2018, doi: 10.1002/mp.13047.
- [7] J. M. Wolterink, A. M. Dinkla, M. H. F. Savenije, P. R. Seevinck, C. A. T. van den Berg, and I. Išgum, "Deep MR to CT Synthesis Using Unpaired Data," Cham, 2017: Springer International Publishing, in *Simulation and Synthesis in Medical Imaging*, pp. 14-23 .
- [8] A. Shokraei Fard, D. C. Reutens, and V. Vegh, "From CNNs to GANs for cross-modality medical image estimation," *Computers in Biology and Medicine*, vol. 146, p. 105556, 2022/07/01/ 2022, doi: <https://doi.org/10.1016/j.compbiomed.2022.105556>.
- [9] Y. Li, W. Li, J. Xiong, J. Xia, and Y. Xie, "Comparison of Supervised and Unsupervised Deep Learning Methods for Medical Image Synthesis between Computed Tomography and Magnetic Resonance Images," *BioMed Research International*, vol. 2020, p0 5 193707, 2020/11/05 2020, doi: 10.1155/2020/5193707.
- [10] J. Johnson, A. Alahi, and L. Fei-Fei, "Perceptual Losses for Real-Time Style Transfer and Super-Resolution," Cham, 2016: Springer International Publishing, in *Computer Vision – ECCV 2016*, pp. 694-711.
- [11] K. Armanious *et al.*, "MedGAN: Medical image translation using GANs," *Computerized Medical Imaging and Graphics*, vol. 79, p. 101684, 2020/01/01/ 2020, doi: <https://doi.org/10.1016/j.compmedimag.2019.101684>.
- [12] S. Tahri *et al.*, "A high-performance method of deep learning for prostate MR-only radiotherapy planning using an optimized Pix2Pix architecture," *Physica Medica: European Journal of Medical Physics*, vol. 103, pp. 108-118, 2022, doi: 10.1016/j.ejmp.2022.10.003.
- [13] RIRE - Retrospective Image Registration Evaluation. [Online]. Available: <https://rire.insight-journal.org/>. Accessed on: 12/21/2022.
- [14] P. Isola, J. Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 21-26 July 2017 2017, pp. 5967-5976, doi: 10.1109/CVPR.2017.632 .
- [15] J.-Y. Zhu, *pytorch-CycleGAN-and-pix2pix*. [Online]. Available: <https://github.com/junyanz/pytorch-CycleGAN-and-pix2pix>. Accessed on: 12/21/2022.
- [16] X. Tie, S. K. Lam, Y. Zhang, K. H. Lee, K. H. Au, and J. Cai, "Pseudo-CT generation from multi-parametric MRI using a novel multi-channel multi-path conditional generative adversarial network for nasopharyngeal carcinoma patients," (in eng), *Med Phys*, vol. 47, no. 4, pp. 1750-1762, Apr 2020, doi: 10.1002/mp.14062.
- [17] S. Roy, J. A. Butman, and D. L. Pham, "Synthesizing CT from Ultrashort Echo-Time MR Images via Convolutional Neural Networks," in *Simulation and Synthesis in Medical Imaging*, Cham, S. A. Tsafaris, A. Gooya, A. F. Frangi, and J. L. Prince, Eds., 2017// 2017: Springer International Publishing, pp. 24-32 .

روش پیشنهادی، فقط به یک تصویر MRI، از یکی از نماهای متداول نیاز دارد. چنین تصویری معمولاً از قبل برای سایر کاربردهای بالینی ثبت شده و موجود است. به عنوان مثال در طراحی درمان پرتودرمانی، به حداقل یک تصویر MRI متداول، برای مشخص کردن محل تومور، نیاز است. با الگوریتم پیشنهادی می توان از همین تصویر موجود، CT را محاسبه و به بدون نیاز به تصویربرداری مجدد، طراحی درمان را تکمیل کرد.

۳-۳ جمع بندی

در این یادداشت روشی مبتنی بر شبکه های مولد متخاصم برای بهبود الگوریتم های تبدیل تصویر MRI به CT معرفی شد. هسته اصلی این روش مدل Pix2Pix است که متناسب با اهداف پژوهش تغییر کرده است.

شبکه مولد بر اساس تابع اتلاف خصمانه، ادراکی و اختلاف تصاویر آموزش دید. مجموعه این توابع اتلاف تلاش می کند شکل نهایی را علاوه بر واقعی بودن، به ساختار آناتومی تصویر MRI نزدیک کنند. با این توابع اتلاف، مولد توانست تصاویر CT ساختگی با MAE ۰.۰۹/۱۸، PSNR ۲۲/۸۰ و SSIM ۰.۸۲۹۷ ایجاد کند.

روش پیشنهادی برای وزن های متداول تصویربرداری MRI قابل استفاده است. با داشتن یک برش دوبعدی MRI از هریک از وزن های T1، T2 یا PD ناحیه مغز، در کسری از ثانیه، تصویر CT محاسبه می شود.

در ادامه لازم است این مدل با داده های بیشتر از چند مرکز درمانی آموزش داده شود تا جامعیت مدل تضمین شود. هم چنین می توان روی CT اصلی و CT ساختگی، محاسبه دوز انجام و مقایسه شود.

سپاس گذاری

این تحقیق با قرارداد به شماره ۱۴۰۰/۱۴۷، با حمایت شرکت بهیار صنعت سپاهان انجام شده است.

مراجع

- [1] M. Boulanger *et al.*, "Deep learning methods to generate synthetic CT from MRI in radiotherapy: A literature review," *Physica Medica*, vol. 89, pp. 265-281, 2021/09/01/ 2021, doi: <https://doi.org/10.1016/j.ejmp.2021.07.027>.
- [2] D. Nie, X. Cao, Y. Gao, L. Wang, and D. Shen, "Estimating CT Image from MRI Data Using 3D Fully Convolutional Networks," (in eng), *Deep Learn Data Label Med Appl (2016)*, vol. 2016, pp. 170-178, 2016, doi: 10.1007/978-3-319-46976-8_18.