

ارائه روش‌های نوین تولید تصاویر مصنوعی با وضوح فوق‌بالا با استفاده از مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه برای کاربردهای پزشکی تشخیصی

جمشید مشهدی

دکترای آموزش زبان انگلیسی، دپارتمان علوم پایه، دانشکده علوم پزشکی شوشتر، شوشتر، ایران

mashhadi-j@shoushtarums.ac.ir

چکیده

تصویربرداری پزشکی با وضوح بالا برای تشخیص دقیق بیماری‌ها، به‌ویژه در شناسایی ضایعات ظریف و ساختارهای آناتومیک کوچک، نقشی حیاتی ایفا می‌کند. با این حال، محدودیت‌های سخت‌افزاری، زمان طولانی اسکن و ناراحتی بیماران، دستیابی به تصاویر با وضوح مطلوب را با چالش مواجه ساخته است. فناوری ابر-تفکیک‌پذیری (Super-Resolution) به‌عنوان یک راهکار پس‌پردازش، امکان افزایش وضوح تصاویر دریافتی را بدون نیاز به ارتقای سخت‌افزار فراهم می‌آورد. در سال‌های اخیر، مدل‌های پخش (Models Diffusion) و شبکه‌های دشمن‌گونه مولد (Networks Adversarial Generative) به‌عنوان دو رویکرد پیشرو در تولید تصاویر مصنوعی با وضوح فوق‌بالا مطرح شده‌اند. این مقاله مروری جامع بر روش‌های نوین تولید تصاویر مصنوعی با وضوح فوق‌بالا با استفاده از مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه برای کاربردهای پزشکی تشخیصی ارائه می‌دهد. ابتدا مبانی نظری و چالش‌های موجود در تصویربرداری پزشکی بررسی می‌شود، سپس معماری‌های پیشرو شامل IM-Diff، OCTDiff، PFEDiff، MDM، LSTMAGAN و FRDAGAN به‌تفصیل معرفی می‌گردند. همچنین معیارهای ارزیابی کمی و کیفی، کاربردهای بالینی و چالش‌های پیش‌روی این روش‌ها مورد بحث قرار می‌گیرد. نتایج نشان می‌دهد که مدل‌های پخش شرطی با حفظ کیفیت ادراکی و شبکه‌های دشمن‌گونه با تولید جزئیات بافتی واقع‌گرایانه، هرکدام نقاط قوت منحصربه‌فردی در کاربردهای پزشکی تشخیصی دارند و ترکیب این دو رویکرد می‌تواند افق‌های جدیدی را در تصویربرداری پزشکی گشاید.

واژگان کلیدی: ابر-تفکیک‌پذیری، مدل‌های پخش شرطی، شبکه‌های دشمن‌گونه مولد، تصویربرداری پزشکی

۱. مقدمه

تصویربرداری پزشکی یکی از ارکان اساسی تشخیص، درمان و پایش بیماری‌ها در پزشکی مدرن به‌شمار می‌رود. روش‌های مختلف تصویربرداری از جمله تشدید مغناطیسی (MRI)، توموگرافی کامپیوتری (CT)، توموگرافی همدوسی نوری (OCT) و سونوگرافی، هرکدام با ارائه اطلاعات منحصر به فردی از ساختارها و عملکردهای درونی بدن، نقش تعیین‌کننده‌ای در فرایند تشخیصی ایفا می‌کنند (al et Wang, ۲۰۲۵a). با این حال، دستیابی به تصاویر با وضوح فضایی بالا همواره با چالش‌های متعددی همراه بوده است. محدودیت‌های سخت‌افزاری، زمان طولانی اسکن، هزینه‌های بالا، حرکت بیمار و نویز ذاتی دستگاه‌های تصویربرداری، عواملی هستند که کیفیت تصاویر بالینی را تحت تأثیر قرار می‌دهند (al et Liu, ۲۰۲۵a).

در تصویربرداری MRI، به دلیل محدودیت‌های سخت‌افزاری و ضخامت برش‌ها، وضوح فضایی تصاویر اغلب برای تأمین نیازهای کاربردهای بالینی کافی نیست (al et Liu, ۲۰۲۵b). تصاویر MRI با وضوح بالا اطلاعات دقیق و غنی‌تری را برای پزشکان فراهم می‌آورند تا ضایعات ظریف را بهتر شناسایی کنند، مرزهای تومور را تعیین نمایند، ساختارهای آناتومیک کوچک را ارزیابی کنند و تغییرات پاتولوژیک مراحل اولیه را که ممکن است در تصاویر با وضوح پایین‌تر پنهان بمانند، تشخیص دهند (al et Liu, ۲۰۲۵c). با این حال، کسب تصاویر MRI با وضوح بالا معمولاً به زمان اسکن طولانی‌تری نیاز دارد که باعث ناراحتی جسمی و روانی بیمار می‌شود و حرکت‌های غیرارادی بیمار می‌تواند منجر به ایجاد آرتیفکت‌های حرکتی و تاری تصاویر گردد (al et Liu, ۲۰۲۵d). در تصویربرداری CT نیز اگرچه سرعت اسکن نسبت به MRI بالاتر است، اما دوز تابش و محدودیت‌های تفکیک‌پذیری آشکارسازها، چالش‌های مشابهی را ایجاد می‌کنند (al et Al-Khoury, ۲۰۲۵).

در سال‌های اخیر، فناوری ابر-تفکیک‌پذیری (Super-Resolution) به عنوان یک راهکار پس‌پردازش کارآمد برای بهبود کیفیت تصاویر پزشکی مطرح شده است (al et Gurappa, ۲۰۲۵). ابر-تفکیک‌پذیری به مجموعه روش‌هایی اطلاق می‌شود که با افزایش وضوح فضایی تصاویر با وضوح پایین، تصاویر با وضوح بالاتر را بازسازی می‌کنند (al et He, ۲۰۲۵a). این روش‌ها به ویژه در شرایطی که امکان اسکن مجدد با وضوح بالا وجود ندارد یا مقرون به صرفه نیست، کاربرد فراوانی دارند. با پیشرفت‌های چشمگیر در حوزه یادگیری عمیق، به ویژه ظهور مدل‌های مولد، رویکردهای ابر-تفکیک‌پذیری تحولی بنیادین یافته‌اند (al et Hassan, ۲۰۲۵).

روش‌های اولیه ابر-تفکیک‌پذیری مبتنی بر یادگیری عمیق عمدتاً بر شبکه‌های عصبی کانولوشنی (CNN) متکی بودند (al et Dong, ۲۰۱۴). این شبکه‌ها با یادگیری نگاشت از تصاویر با وضوح پایین به تصاویر با وضوح بالا، توانستند بهبودهای قابل توجهی در معیارهای کمی مانند نسبت سیگنال به نویز پیک (PSNR) و شاخص تشابه ساختاری (SSIM) ایجاد کنند. با این حال، روش‌های مبتنی بر CNN اغلب به تولید تصاویر صاف و فاقد جزئیات بافتی واقع‌گرایانه منجر می‌شوند و در بازسازی بافت‌های پیچیده و جزئیات ظریف عملکرد مطلوبی ندارند (al et Liu, ۲۰۲۵b).

برای رفع این محدودیت‌ها، شبکه‌های دشمن‌گونه مولد (GAN) به عنوان رویکردی نوین در ابر-تفکیک‌پذیری تصاویر پزشکی مطرح شدند (al et Zhang, ۲۰۲۵a). GAN‌ها با استفاده از یک ساختار رقابتی بین تولیدکننده و تشخیص‌دهنده، قادر به تولید تصاویری با کیفیت ادراکی بالا و جزئیات بافتی واقع‌گرایانه هستند (al et Goodfellow, ۲۰۱۴). با این حال، GAN‌ها با چالش‌هایی مانند بی‌ثباتی در آموزش، فروپاشی حالت (Collapse Mode) و تولید آرتیفکت‌های مصنوعی مواجه هستند (al et Zhang, ۲۰۲۵d).

در سال‌های اخیر، مدل‌های پخش (Models Diffusion) به‌عنوان نسل جدیدی از مدل‌های مولد، توجه گسترده‌ای را در حوزه ابر-تفکیک‌پذیری تصاویر پزشکی به خود جلب کرده‌اند (al et Sui, ۲۰۲۵). این مدل‌ها با الهام از فرایندهای ترمودینامیکی، از یک فرایند انتشار رو به جلو برای افزودن تدریجی نویز به داده و یک فرایند انتشار معکوس برای حذف نویز و بازسازی داده استفاده می‌کنند (al et He, ۲۰۲۵b). مدل‌های پخش شرطی (Models Diffusion Conditional) با استفاده از اطلاعات شرطی مانند تصویر با وضوح پایین، قادر به تولید تصاویر با وضوح بالا با کیفیت فوق‌العاده هستند (Liu et al, ۲۰۲۵a).

هدف این مقاله، ارائه مروری جامع و به‌روز بر روش‌های نوین تولید تصاویر مصنوعی با وضوح فوق‌بالا با استفاده از مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه برای کاربردهای پزشکی تشخیصی است. این مقاله به بررسی مبانی نظری، معماری‌های پیشرو، معیارهای ارزیابی، کاربردهای بالینی و چالش‌های موجود می‌پردازد و چشم‌انداز آینده این حوزه را ترسیم می‌نماید.

ساختار مقاله به‌این‌صورت است: در بخش دوم، مبانی نظری ابر-تفکیک‌پذیری و مدل‌های مولد بررسی می‌شود. بخش سوم به معرفی روش‌های پیشرو مبتنی بر مدل‌های پخش شرطی اختصاص دارد. بخش چهارم روش‌های مبتنی بر شبکه‌های دشمن‌گونه را پوشش می‌دهد. بخش پنجم معیارهای ارزیابی و بخش ششم کاربردهای بالینی را مورد بحث قرار می‌دهد. بخش هفتم به چالش‌ها و بخش هشتم به نتیجه‌گیری و چشم‌انداز آینده اختصاص دارد.

۲. مبانی نظری

۲.۱. ابر-تفکیک‌پذیری تصاویر پزشکی

ابر-تفکیک‌پذیری (Super-Resolution) به فرایند بازسازی یک تصویر با وضوح بالا از یک یا چند تصویر با وضوح پایین اطلاق می‌شود (al et He, ۲۰۲۵a). در کاربردهای پزشکی، این مسئله به‌دلیل ماهیت معکوس (Ill-posed) خود، از چالش‌برانگیزترین مسائل در بینایی ماشین محسوب می‌شود؛ زیرا از یک ورودی با وضوح پایین، بی‌شمار خروجی با وضوح بالا امکان‌پذیر است که هرکدام از نظر جزئیات و شفافیت با یکدیگر تفاوت دارند (Liu et al, ۲۰۲۵a).

از نظر ریاضی، مسئله ابر-تفکیک‌پذیری را می‌توان به‌صورت زیر مدل‌سازی کرد:

$$ILR=D)IHR(+n)ILR=D)IHR(+n$$

که در آن ILR/ILR تصویر با وضوح پایین، IHR/IHR تصویر با وضوح بالا، DD عملگر تخریب (شامل زیرنمونه‌برداری، تاری و نویز) و nn نویز است. هدف، یافتن تخمینی از IHR/IHR با استفاده از ILR/ILR است (al et He, ۲۰۲۵b).

در تصویربرداری پزشکی، چالش‌های خاصی وجود دارد که ابر-تفکیک‌پذیری را پیچیده‌تر می‌سازد (al et Wang, ۲۰۲۵b):

- **حفظ ساختارهای آناتومیک:** تصاویر پزشکی حاوی ساختارهای آناتومیک ظریف و حیاتی هستند که هرگونه انحراف یا توهم در بازسازی می‌تواند به تشخیص اشتباه منجر شود.

- **ماهیت چند-مده:** تصاویر پزشکی در مودالیت‌های مختلف (PET, CT, MRI و غیره) با ویژگی‌های آماری و فیزیکی متفاوت تولید می‌شوند.
- **محدودیت داده‌های آموزشی:** داده‌های تصویربرداری پزشکی اغلب محدود، گران‌قیمت و نیازمند تأیید متخصصان هستند.
- **نیاز به قابلیت تعمیم‌پذیری:** مدل‌ها باید بتوانند بر روی داده‌های مراکز مختلف با پروتکل‌های تصویربرداری گوناگون عملکرد مناسبی داشته باشند.

۲.۲. شبکه‌های دشمن‌گونه مولد (GAN)

شبکه‌های دشمن‌گونه مولد (GAN) که توسط Goodfellow و همکاران (۲۰۱۴) معرفی شدند، از دو شبکه عصبی تشکیل شده‌اند: تولیدکننده (Generator) و تشخیص‌دهنده (Discriminator). تولیدکننده سعی می‌کند نمونه‌های مصنوعی شبیه به داده‌های واقعی تولید کند، در حالی که تشخیص‌دهنده تلاش می‌کند نمونه‌های واقعی را از نمونه‌های مصنوعی تشخیص دهد. این دو شبکه در یک بازی مینی-مکس با یکدیگر رقابت می‌کنند (al et Zhang, ۲۰۲۵a).

در ابر-تفکیک‌پذیری مبتنی بر GAN، تولیدکننده تصویر با وضوح پایین را به‌عنوان ورودی دریافت و تصویر با وضوح بالا را تولید می‌کند. تشخیص‌دهنده سپس تصویر تولیدشده را با تصویر واقعی با وضوح بالا مقایسه می‌کند و به تولیدکننده بازخورد می‌دهد (al et Zhang, ۲۰۲۵a).

تابع هزینه در GAN‌های ابر-تفکیک‌پذیری معمولاً ترکیبی از سه جزء است (al et Zhang, ۲۰۲۵a):

۱. **هزینه دشمن‌گونه (Loss Adversarial):** تولیدکننده را به تولید تصاویر واقع‌گرایانه تشویق می‌کند.
۲. **هزینه بازسازی (Loss Reconstruction):** معمولاً با استفاده از خطای میانگین مربعات (MSE) یا خطای قدرمطلق (L1) بین تصویر تولیدشده و تصویر مرجع محاسبه می‌شود.
۳. **هزینه ادراکی (Loss Perceptual):** با مقایسه ویژگی‌های استخراج‌شده از یک شبکه پیش‌آموزش‌دیده (مانند VGG) بین تصویر تولیدشده و تصویر مرجع محاسبه می‌شود.

با وجود موفقیت‌های چشمگیر، GAN‌ها با چالش‌های اساسی مواجه هستند (al et Zhang, ۲۰۲۵a):

- **بی‌ثباتی در آموزش:** نوسان‌های شدید در تابع هزینه و واگرایی آموزش.
- **فروپاشی حالت (Collapse Mode):** تولیدکننده تنها زیرمجموعه محدودی از تنوع داده‌ها را یاد می‌گیرد.
- **تولید آرتیفکت:** تولید ساختارهای مصنوعی و غیرواقعی در تصاویر خروجی.

۲.۳. مدل‌های پخش (Models Diffusion)

مدل‌های پخش (Models Diffusion) که با نام مدل‌های پخش احتمالی واهسته‌سازی (Diffusion Denoising) (DDPM - Models Probabilistic) نیز شناخته می‌شوند، توسط Ho و همکاران (۲۰۲۰) معرفی شدند. این مدل‌ها از دو فرایند اصلی تشکیل شده‌اند (al et Sui, ۲۰۲۵):

فرایند انتشار رو به جلو (Process Diffusion Forward): در این فرایند، نویز گاوسی به تدریج به داده افزوده می‌شود تا داده به‌طور کامل به نویز خالص تبدیل شود (al et He, ۲۰۲۵b):

$$q(x_t|x_{t-1}) = \mathcal{N}(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t I)$$

که در آن x_t داده در زمان t ، β_t برنامه نویز در زمان t و I ماتریس همانی است.

فرایند انتشار معکوس (Process Diffusion Reverse): در این فرایند، یک شبکه عصبی آموزش می‌بیند تا نویز افزوده‌شده را پیش‌بینی و حذف کند و داده را از نویز خالص به داده اصلی بازگرداند (al et Sui, ۲۰۲۵):

$$p(\theta)(x_t|x_{t-1}) = \mathcal{N}(x_t; \mu(\theta)(x_t, t), \Sigma(\theta)(x_t, t))$$

مزایای اصلی مدل‌های پخش عبارتند از (al et Liu, ۲۰۲۵b; al et Sui, ۲۰۲۵):

- **کیفیت تولید فوق‌العاده:** مدل‌های پخش قادر به تولید تصاویری با کیفیت ادراکی بسیار بالا و جزئیات دقیق هستند.
- **پایداری در آموزش:** برخلاف GANها، فرایند آموزش مدل‌های پخش پایدارتر است و با مشکلات فروپاشی حالت مواجه نیست.
- **تنوع بالا:** این مدل‌ها می‌توانند تنوع غنی‌ای از خروجی‌ها را تولید کنند.

با این حال، مدل‌های پخش با چالش‌هایی نیز روبرو هستند (al et Liu, ۲۰۲۵b):

- **هزینه محاسباتی بالا:** فرایند نمونه‌برداری در مدل‌های پخش نیازمند صدها یا هزاران مرحله پیمایش است که زمان‌بر و پرهزینه است.
- **سرعت نمونه‌برداری پایین:** به دلیل تعداد زیاد مراحل، نمونه‌برداری در مدل‌های پخش کندتر از GANهاست.

۲.۴. مدل‌های پخش شرطی (Models Diffusion Conditional)

مدل‌های پخش شرطی (Models Diffusion Conditional) توسعه‌یافته مدل‌های پخش پایه هستند که امکان هدایت فرایند تولید با استفاده از اطلاعات شرطی را فراهم می‌آورند (al et Liu, ۲۰۲۵a). در ابر-تفکیک‌پذیری، تصویر با وضوح پایین به‌عنوان شرط (Condition) به مدل پخش داده می‌شود تا فرایند تولید تصویر با وضوح بالا را هدایت کند (al et Liu, ۲۰۲۵a).

فرایند انتشار معکوس در مدل‌های پخش شرطی به صورت زیر تعریف می‌شود (al et Liu, ۲۰۲۵a):

$$p(\theta)_{x_{t-1}|x_{t,c}(=N)_{x_{t-1}};\mu(\theta)_{x_{t,t,c}(\Sigma\theta)_{x_{t,t,c}((p\theta)_{x_{t-1}|x_{t,c}(=N)_{x_{t-1}};\mu(\theta)_{x_{t,t,c}(\Sigma\theta)_{x_{t,t,c}(($$

که در آن CC اطلاعات شرطی (مانند تصویر با وضوح پایین) است.

مدل‌های پخش شرطی مزایای متعددی دارند (al et Liu, ۲۰۲۵a; al et Wang, ۲۰۲۵c):

- تولید هدفمند: امکان تولید تصاویر با ویژگی‌های خاص با استفاده از اطلاعات شرطی.
- کیفیت بالاتر: استفاده از اطلاعات شرطی به مدل کمک می‌کند تا جزئیات دقیق‌تری را بازسازی کند.
- کنترل‌پذیری بیشتر: کاربر می‌تواند با تغییر اطلاعات شرطی، خروجی‌های مختلفی را تولید کند.

۳. روش‌های پیشرو مبتنی بر مدل‌های پخش شرطی

در این بخش، روش‌های پیشرو در تولید تصاویر مصنوعی با وضوح فوق‌بالا با استفاده از مدل‌های پخش شرطی برای کاربردهای پزشکی تشخیصی معرفی و بررسی می‌شوند.

۳.۱. IM-Diff: مدل پخش ضمنی چند-کنتراستی برای ابر-تفکیک‌پذیری MRI در مقیاس دلخواه

مدل IM-Diff (Model Diffusion Multi-Contrast Implicit) که توسط Liu و همکاران (۲۰۲۵a) ارائه شده است، یک مدل پخش شرطی نوین برای ابر-تفکیک‌پذیری تصاویر MRI در مقیاس‌های دلخواه است. این مدل با هدف رفع دو چالش اساسی در مدل‌های پخش موجود طراحی شده است: (۱) بهره‌برداری ناکافی از اطلاعات مکمل تصاویر چند-کنتراستی که بازسازی دقیق جزئیات بافتی و ساختارهای آناتومیک را با مانع مواجه می‌سازد، و (۲) وابستگی به ضرایب بزرگنمایی ثابت (مانند $\times 2$ یا $\times 4$) که در سناریوهای بالینی که نیاز به بزرگنمایی در مقیاس‌های دلخواه دارند، کاربردی نیست (al et Liu, ۲۰۲۵a).

معماری IM-Diff از دو مؤلفه اصلی تشکیل شده است (al et Liu, ۲۰۲۵a):

۱. ماژول ادغام سلسله‌مراتبی چند-کنتراستی (HMF - Fusion Multi-Contrast Hierarchical): این ماژول با استفاده از بلوک Mamba آگاه از مرجع (RCM - Mamba Cross Reference-aware)، اطلاعات مربوط به تصویر هدف را از تصویر مرجع به طور مؤثر استخراج و ادغام می‌کند. بلوک RCM با حفظ یک میدان دریافتی وسیع و کارایی محاسباتی بالا، امکان استخراج اطلاعات مکمل از تصاویر چند-کنتراستی را فراهم می‌آورد (al et Liu, ۲۰۲۵a).

۲. ماژول‌های بزرگنمایی با نمایش ضمنی عصبی موجکی (WINRM - Magnification INR Wavelet): این ماژول‌ها با ادغام غیرخطی‌های ضمنی عصبی موجکی در فرایند واهسته‌سازی، یادگیری نمایش‌های پیوسته از تصاویر MRI

را ممکن می‌سازند. فعال‌سازی موجکی باعث افزایش تمرکز فضایی-فرکانسی و بهبود دقت و استحکام نمایش در INR می‌شود (al et Liu, ۲۰۲۵a).

نتایج آزمایش‌های گسترده بر روی سه مجموعه داده عمومی نشان‌دهنده برتری روش IM-Diff نسبت به مدل‌های پیشرفته موجود در ضرایب بزرگنمایی مختلف است (al et Liu, ۲۰۲۵a).

۳.۲. OCTDiff: مدل پخش پل‌شده برای ابر-تفکیک‌پذیری و بهبود OCT قابل حمل

مدل OCTDiff (Model Diffusion Bridged) که توسط Tian و همکاران (۲۰۲۵) ارائه شده است، یک مدل پخش تصویر-به-تصویر برای بهبود وضوح و کیفیت تصاویر دستگاه‌های OCT (Tomography Coherence Optical) قابل حمل است. ابر-تفکیک‌پذیری در تصویربرداری پزشکی برای بهبود کارایی تشخیصی و کاهش هزینه‌ها حیاتی است، به‌ویژه برای مودالیت‌های کم‌هزینه مانند OCT قابل حمل (al et Tian, ۲۰۲۵).

OCTDiff چالش‌های کلیدی در فرایند تولید شرطی مدل‌های پخش واهسته‌سازی (DDPM) را با سه نوآوری اصلی مورد بررسی قرار می‌دهد (al et Tian, ۲۰۲۵):

۱. **تجمیع نویز تطبیقی (ANA - Aggregation Noise Adaptive)**: یک ماژول نوین برای بهبود دینامیک واهسته‌سازی در فرایند انتشار معکوس.

۲. **توجه متقاطع چند-مقیاس (MSCA - Cross-Attention Multi-Scale)**: این ماژول در هسته U-Net ادغام شده است تا وابستگی‌های محلی را در تفکیک‌پذیری‌های فضایی مختلف کند.

۳. **تابع هزینه سفارشی**: برای مقابله با بیش‌برازش در مجموعه داده‌های بالینی کوچک و حفظ جزئیات ساختاری ظریف ضروری برای تشخیص‌های شبکه‌ای، یک تابع هزینه سفارشی با هدایت نمرات کیفیت بالینی طراحی شده است (al et Tian, ۲۰۲۵).

نتایج نشان می‌دهد که OCTDiff از پایه‌های کانولوشنی و DDPM‌های استاندارد پیشی گرفته و عملکرد پیشرفته‌ای را در مجموعه داده‌های بالینی OCT قابل حمل به دست آورده است (al et Tian, ۲۰۲۵).

۳.۳. PFEDiff: مدل پخش کارآمد با ویژگی‌های قبلی برای ابر-تفکیک‌پذیری تصاویر MRI سه‌بعدی

مدل PFEDiff (Model Diffusion Efficient Feature Prior) که توسط Liu و همکاران (۲۰۲۵b) ارائه شده است، یک مدل پخش کارآمد برای ابر-تفکیک‌پذیری تصاویر MRI سه‌بعدی با هدف بهبود تحلیل کانکتومیکس مغز طراحی شده است. روش‌های مبتنی بر یادگیری عمیق برای ابر-تفکیک‌پذیری MRI اغلب به کیفیت بصری ضعیف و صافی بیش از حد منجر می‌شوند، در حالی که روش‌های مبتنی بر پخش می‌توانند جزئیات پیچیده و جذاب از نظر ادراکی تولید کنند اما نیازمند مراحل پخش متعدد هستند (al et Liu, ۲۰۲۵b).

PFEDiff با سه نوآوری اصلی این چالش‌ها را برطرف می‌کند (al et Liu, ۲۰۲۵b):

۱. استفاده از نقشه‌های اختلاف وضوح (**RDMs - Maps Disparity Resolution**) به‌عنوان هدف: به‌جای بازیابی محتوای فرکانس بالا و پایین، مدل پخش بر روی بازیابی محتوای اختلاف در تصاویر MRI از نویز متمرکز می‌شود که کارایی تولید را به‌شدت افزایش می‌دهد. PFEDiff تنها به ۵۰ مرحله نمونه‌برداری برای دستیابی به نتایج قانع‌کننده نیاز دارد (al et Liu, ۲۰۲۵b).

۲. ماژول تقویت اطلاعات قبلی (**PIEM - Module Enhancement Information Prior**): این ماژول ویژگی‌های قبلی بیشتری را به مدل پخش وارد می‌کند و امکان بازیابی دقیق و قابلیت تعمیم‌پذیری بالاتر را فراهم می‌آورد (al et Liu, ۲۰۲۵b).

۳. پیش‌بینی‌کننده نویز با توجه باقیمانده (**Predictor Noise Attention Residual**): این مؤلفه ویژگی‌های مفید را تقویت و ویژگی‌های نامربوط را فیلتر می‌کند و پیش‌بینی پیشرفته نویز را در هر مرحله از فرایند انتشار معکوس تضمین می‌نماید (al et Liu, ۲۰۲۵b).

نتایج آزمایش‌ها نشان می‌دهد که PFEDiff از روش‌های پیشرفته موجود بهتر عمل می‌کند و در مقایسه با مدل‌های پخش پایه، سرعت نمونه‌برداری بیش از ۱۰ برابر سریع‌تر دارد (al et Liu, ۲۰۲۵b). همچنین، کاربرد PFEDiff در تحلیل کانکتومیکس مغز، پتانسیل بالینی این روش را تأیید کرده است (al et Liu, ۲۰۲۵b).

۳.۴. MDM: مدل پخش تقویت‌شده با Mamba برای ابر-تفکیک‌پذیری کور آگاه از ادراک MRI

مدل MDM (Model Diffusion Mamba-enhanced) که توسط Liu و همکاران (۲۰۲۵c) ارائه شده است، یک مدل پخش نوین برای ابر-تفکیک‌پذیری کور (Super-Resolution Blind) تصاویر MRI با آگاهی از ادراک است. تصاویر MRI با وضوح بالا اطلاعات دقیقی را برای تشخیص ضایعات ظریف، تعیین مرزهای تومور و ارزیابی ساختارهای آناتومیک کوچک فراهم می‌آورند، اما کسب این تصاویر نیازمند زمان اسکن طولانی است که می‌تواند منجر به آرتیفکت‌های حرکتی و تاری تصاویر شود (al et Liu, ۲۰۲۵c).

MDM از دو مؤلفه اصلی تشکیل شده است (al et Liu, ۲۰۲۵c):

۱. تخمین‌گر هسته تاری آگاه از ادراک (**PBKN - Estimator Noise Kernel Blur Perception-aware**)

(**Estimator**): این مؤلفه از مدل پخش برای تخمین هسته تاری از تصاویر با وضوح پایین استفاده می‌کند.

۲. بازسازی‌کننده ویژگی پیش‌رونده (**Reconstructor Feature Progressive**): این مؤلفه با استفاده از هسته تاری تخمین‌زده‌شده و اطلاعات محتوایی تصاویر با وضوح پایین به‌عنوان دانش قبلی، تصاویر MRI با وضوح بالا را با دقت بیشتری بازسازی می‌کند. همچنین، یک ماژول جدید به نام SIF-Mamba (Fusion Information Semantic) برای 捕获 (Mamba) بافت کلی تصاویر MRI و بهبود بازسازی ویژگی طراحی شده است (al et Liu, ۲۰۲۵c).

نتایج آزمایش‌های گسترده نشان می‌دهد که MDM نتایج بازسازی بهتری نسبت به چندین روش برجسته دیگر به دست می‌آورد (al et Liu, ۲۰۲۵c).

۳.۵. سایر روش‌های مبتنی بر مدل‌های پخش شرطی

علاوه بر روش‌های فوق، روش‌های دیگری نیز در سال‌های اخیر برای ابر-تفکیک‌پذیری تصاویر پزشکی با استفاده از مدل‌های پخش شرطی ارائه شده‌اند:

ICDSR (Model Diffusion Conditional Integrated): این مدل توسط Liu و همکاران (۲۰۲۵d) برای ابر-تفکیک‌پذیری تک‌تصویر (SISR) ارائه شده است. ICDSR با رمزگذاری تصویر با وضوح پایین به‌عنوان شرط برای تولید ویژگی‌های قبلی و ادغام آن با اطلاعات گام زمانی، محدودیت‌های میانی را ایجاد می‌کند. یک ساختار هدایت چند-مقیاسی برای اتصال U-شکل مدل پخش طراحی شده است که اطلاعات یکپارچه‌شده چند-مقیاسی را به بلوک پایه مدل پخش تزریق می‌کند (al et Liu, ۲۰۲۵d).

BUFF (Model Probabilistic Diffusion Guided Uncertainty Bayesian): این مدل توسط He و همکاران (۲۰۲۵b) ارائه شده است و از یک شبکه بیزی برای تولید ماسک‌های عدم قطعیت با وضوح بالا استفاده می‌کند. این ماسک‌ها فرایند پخش را هدایت کرده و امکان تنظیم شدت نویز را به‌صورت آگاه از بافت و تطبیقی فراهم می‌آورند. BUFF وفاداری تصاویر ابر-تفکیک‌شده را افزایش می‌دهد و آرتیفکت‌ها و تارگی را در مناطق با بافت‌های پیچیده و جزئیات ظریف به‌طور قابل توجهی کاهش می‌دهد (al et He, ۲۰۲۵b).

DiffCode: این چارچوب توسط Chen و همکاران (۲۰۲۵) برای بازسازی همه-کاره تصاویر پزشکی (All-in-One MedIR) ارائه شده است. DiffCode با استفاده از یک بانک کدبوک تطبیقی با وظیفه و یک استراتژی پخش نهفته، امکان بازسازی همزمان تصاویر CT، MRI و PET را فراهم می‌آورد (al et Chen, ۲۰۲۵).

۴. روش‌های پیشرو مبتنی بر شبکه‌های دشمن‌گونه مولد

در این بخش، روش‌های پیشرو در تولید تصاویر مصنوعی با وضوح فوق‌بالا با استفاده از شبکه‌های دشمن‌گونه مولد برای کاربردهای پزشکی تشخیصی معرفی و بررسی می‌شوند.

۴.۱. **LSTMAGAN**: شبکه دشمن‌گونه مولد با حافظه کوتاه-مدت و بلندمدت و توجه برای ابر-تفکیک‌پذیری تصاویر پزشکی سه‌بعدی

مدل LSTMAGAN (Generative based Attention and Memory Short-Term Long Network Adversarial) که توسط Zhang و همکاران (۲۰۲۵b) در Reports Scientific ارائه شده است، یک شبکه دشمن‌گونه مولد برای ابر-تفکیک‌پذیری تصاویر پزشکی سه‌بعدی است. از آنجا که داده‌های تصویربرداری پزشکی سه‌بعدی

به‌صورت دنباله‌ای از تصاویر متوالی هستند، همبستگی قوی بین تصاویر متوالی وجود دارد. شبکه‌های کانولوشنی عمیق در استخراج ویژگی‌های فضایی عملکرد خوبی دارند، اما در پردازش داده‌های دنباله‌ای نسبت به شبکه‌های کانولوشنی بازگشتی (Networks Convolutional Recurrent) توانایی کمتری دارند (al et Zhang, ۲۰۲۵b).

معماری LSTMAGAN از سه مؤلفه اصلی تشکیل شده است (al et Zhang, ۲۰۲۵b):

۱. شبکه دشمن‌گونه مولد به‌عنوان مدل پایه: برای بازسازی تصاویر ابر-تفکیک‌پذیر.
 ۲. شبکه حافظه کوتاه-مدت و بلندمدت (LSTM): برای پردازش داده‌های دنباله‌ای پیوسته تصاویر پزشکی سه‌بعدی بر اساس توانایی آن در به‌خاطر سپاری و فراموشی کارآمد اطلاعات.
 ۳. دروازه توجه (Gate Attention): برای سرکوب اطلاعات نویز پس‌زمینه و بهبود وضوح ویژگی‌های تصویر (Zhang et al, ۲۰۲۵b).
- نتایج آزمایش‌ها بر روی مجموعه داده‌های LUNA16 و BraTS2021 نشان می‌دهد که روش پیشنهادی شاخص‌های PSNR و SSIM را در مقایسه با سایر روش‌ها بهبود می‌بخشد (al et Zhang, ۲۰۲۵b).

۴.۲. FRDAGAN: شبکه دشمن‌گونه مولد با ادغام بلوک‌های متراکم باقیمانده و توجه

مدل Adversarial Generative in Attention and Dense Residual Fusing) FRDAGAN (Network Surgery and Medicine in Imaging Quantitative در Zhang و همکاران (۲۰۲۵a) ارائه شده است، یک شبکه دشمن‌گونه مولد برای ابر-تفکیک‌پذیری تصاویر پزشکی است. وضوح تصاویر پزشکی بالینی ممکن است به دلیل تفاوت در دوز تابش، تجهیزات نمونه‌برداری و روش‌های ذخیره‌سازی کاهش یابد. تصاویر پزشکی با وضوح پایین، اطلاعات ویژگی‌های ضایعه را مبهم کرده و دقت تشخیصی پزشکان را تحت تأثیر قرار می‌دهند (al et Zhang, ۲۰۲۵a).

FRDAGAN از سه مؤلفه اصلی تشکیل شده است (al et Zhang, ۲۰۲۵a):

۱. بلوک‌های متراکم باقیمانده (Blocks Dense Residual): برای استفاده کامل از اطلاعات ویژگی لایه‌های مختلف و جلوگیری از کاهش گرادیان.
۲. شبکه دروازه توجه (Gate Attention): برای سرکوب اطلاعات نویز و بهبود نسبت سیگنال به نویز (Zhang et al, ۲۰۲۵a).
۳. تابع هزینه ترکیبی (Function Loss Hybrid): برای جلوگیری از محو یا انفجار گرادیان در شبکه (Zhang et al, ۲۰۲۵a).

نتایج کمی بر روی مجموعه داده LUNA16 و مجموعه داده MRI مغز نشان می‌دهد که FRDAGAN عملکرد بهتری نسبت به سایر روش‌ها دارد. بر روی مجموعه داده LUNA16 با استفاده از تصاویر تکی، مقادیر PSNR و SSIM به ترتیب

۰۳۳/۰۵±۱۵۷/۰ و ۰۲۸/۰±۹۳۸/۰ و بر روی مجموعه داده MRI مغز به ترتیب ۰۳۵/۰±۲۷۰/۱۸۳ و ۰۸۸۹/۰±۰۲۴ به دست آمد (al et Zhang, ۲۰۲۵a).

۴.۳. AttentionGAN: شبکه دشمن‌گونه مولد با توجه برای دقت تشخیصی در MRI

مدل AttentionGAN که توسط Liu و همکاران (۲۰۲۵e) ارائه شده است، یک شبکه دشمن‌گونه مولد با مکانیسم‌های توجه برای ابر-تفکیک‌پذیری تصاویر MRI است. GAN‌های متداول ممکن است ویژگی‌های آناتومیک ظریف حیاتی برای تشخیص دقیق را نادیده بگیرند. AttentionGAN با ادغام مکانیسم‌های توجه که تمرکز شبکه را به سمت مناطق مهم بالینی مانند مرزهای ضایعه و سطوح بافتی هدایت می‌کنند، این شکاف را پر می‌کند و بازسازی‌های شارپ‌تر و اطلاعاتی‌تری را ارائه می‌دهد (al et Liu, ۲۰۲۵e).

AttentionGAN از ترکیبی از توجه خود، توجه کانالی و توجه فضایی برای بهبود عملکرد بر روی مجموعه داده MRI مغز استفاده می‌کند (al et Liu, ۲۰۲۵e).

۴.۴. LSTMAGAN: شبکه دشمن‌گونه مولد با حافظه کوتاه-مدت و بلندمدت و توجه

همان‌طور که در بخش ۴.۱ تشریح شد، LSTMAGAN یک رویکرد نوین برای ابر-تفکیک‌پذیری تصاویر پزشکی سه‌بعدی با استفاده از ترکیب LSTM، GAN و مکانیسم‌های توجه است. این روش با بهره‌گیری از همبستگی بین تصاویر متوالی در داده‌های سه‌بعدی و سرکوب نویز پس‌زمینه، بهبود قابل توجهی در کیفیت بازسازی ایجاد می‌کند (al et Zhang, ۲۰۲۵b).

۴.۵. سایر روش‌های مبتنی بر شبکه‌های دشمن‌گونه مولد

روش‌های دیگری نیز بر اساس GAN برای ابر-تفکیک‌پذیری تصاویر پزشکی ارائه شده‌اند:

MSFF-GAN (GAN Fusion Feature Multi-Scale): این روش توسط Liu و همکاران (۲۰۲۵f) در حوزه تبدیل دامنه برای ابر-تفکیک‌پذیری تصاویر پزشکی ارائه شده است و از ادغام ویژگی‌های چند-مقیاسی عمیق برای بهبود کیفیت بازسازی استفاده می‌کند.

CL-GAN (GAN Learning Curriculum): این روش توسط Al-Khoury و همکاران (۲۰۲۵) برای ابر-تفکیک‌پذیری تصاویر CT استخوان با استفاده از یادگیری برنامه‌درسی پیشرونده ارائه شده است.

SRGAN و ESRRGAN: این روش‌ها به‌عنوان پایه‌های اصلی ابر-تفکیک‌پذیری مبتنی بر GAN، در کاربردهای پزشکی مختلف از جمله CT و MRI مورد استفاده قرار گرفته‌اند (al et Al-Khoury, ۲۰۲۵; al et Liu, ۲۰۲۵e).

۵. معیارهای ارزیابی

ارزیابی روش‌های ابر-تفکیک‌پذیری تصاویر پزشکی نیازمند مجموعه‌ای از معیارهای کمی و کیفی است که جنبه‌های مختلف کیفیت تصویر را مورد سنجش قرار دهند (al et Gurappa, ۲۰۲۵).

۵.۱. معیارهای کمی

PSNR (Ratio Signal-to-Noise Peak): نسبت سیگنال به نویز پیک، یکی از رایج‌ترین معیارهای ارزیابی کیفیت بازسازی است که خطای میانگین مربعات (MSE) بین تصویر بازسازی‌شده و تصویر مرجع را اندازه‌گیری می‌کند. مقادیر بالاتر PSNR نشان‌دهنده کیفیت بهتر است (al et Zhang, ۲۰۲۵a).

SSIM (Measure Index Similarity Structural): شاخص تشابه ساختاری، شباهت ادراکی بین دو تصویر را بر اساس سه مؤلفه روشنایی، کنتراست و ساختار اندازه‌گیری می‌کند. مقادیر SSIM بین ۰ و ۱ متغیر است و مقادیر بالاتر نشان‌دهنده شباهت بیشتر است. به‌طور کلی، مقادیر SSIM بالای ۹۵/۰ عالی، بین ۸۵/۰ تا ۹۵/۰ خوب و بین ۷۰/۰ تا ۸۵/۰ متوسط در نظر گرفته می‌شوند (al et Wang, ۲۰۲۵d).

LPIPS (Similarity Patch Image Perceptual Learned): این معیار با استفاده از یک شبکه عصبی پیش‌آموزش‌دیده، شباهت ادراکی بین تصاویر را اندازه‌گیری می‌کند و با معیارهای ادراکی انسانی همبستگی بالایی دارد (He et al, ۲۰۲۵b).

FID (Distance Inception Fréchet): این معیار فاصله بین توزیع ویژگی‌های تصاویر تولیدشده و تصاویر واقعی را در فضای ویژگی‌های یک شبکه عصبی اندازه‌گیری می‌کند و معیاری برای ارزیابی کیفیت و تنوع تصاویر تولیدشده است (Sui et al, ۲۰۲۵).

۵.۲. معیارهای کیفی

علاوه بر معیارهای کمی، ارزیابی کیفی توسط متخصصان بالینی نیز از اهمیت بالایی برخوردار است (al et Gurappa, ۲۰۲۵).

ارزیابی بالینی توسط رادیولوژیست‌ها: متخصصان تصویربرداری، کیفیت تشخیصی تصاویر بازسازی‌شده را از نظر وضوح ساختارهای آناتومیک، تشخیص ضایعات و کاربرد بالینی بررسی می‌کنند (al et Tian, ۲۰۲۵).

آزمون تورینگ بصری (Test Turing Visual): در این آزمون، متخصصان تفاوت بین تصاویر واقعی و تصاویر تولیدشده را تشخیص می‌دهند و عملکرد مدل بر اساس میزان تشخیص‌پذیری ارزیابی می‌شود (al et Chen, ۲۰۲۵).

ارزیابی تأثیر بر وظایف بالینی: یکی از معیارهای مهم، بررسی تأثیر ابر-تفکیک‌پذیری بر عملکرد مدل‌های تشخیصی پایین‌دست (Tasks Downstream) مانند تقسیم‌بندی (Segmentation) و طبقه‌بندی (Classification) است (al et Gurappa, ۲۰۲۵).

۶. کاربردهای بالینی

روش‌های ابر-تفکیک‌پذیری مبتنی بر مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه کاربردهای گسترده‌ای در حوزه تشخیص پزشکی دارند.

۶.۱. تصویربرداری تشدید مغناطیسی (MRI)

ابر-تفکیک‌پذیری در MRI کاربردهای متعددی دارد (al et Liu, ۲۰۲۵b):

- **تصویربرداری مغز:** بهبود وضوح تصاویر MRI مغز برای تشخیص بیماری‌های نورودژنراتیو مانند آلزایمر، ضایعات مغزی و تومورها (al et Liu, ۲۰۲۵b). مطالعات نشان داده است که مدل PFEDiff با بازسازی تصاویر MRI با وضوح بالا، عملکرد تحلیل کانکتومیکس مغز را بهبود می‌بخشد (al et Liu, ۲۰۲۵b).
- **تصویربرداری چند-کنتراستی MRI:** مدل IM-Diff با استفاده از اطلاعات مکمل تصاویر چند-کنتراستی، بازسازی دقیق‌تری از جزئیات بافتی و ساختارهای آناتومیک ارائه می‌دهد (al et Liu, ۲۰۲۵a).
- **تصویربرداری کاردیو:** ابر-تفکیک‌پذیری در MRI قلب برای بهبود تصاویر با وضوح پایین ناشی از حرکت قلبی و تنفسی کاربرد دارد (al et Wang, ۲۰۲۵d).
- **تصویربرداری پروستات:** بهبود کیفیت تصاویر DWI برای تشخیص سرطان پروستات (al et Wang, ۲۰۲۵d).

۶.۲. توموگرافی کامپیوتری (CT)

در تصویربرداری CT، روش‌های ابر-تفکیک‌پذیری برای موارد زیر استفاده می‌شوند (al et Al-Khoury, ۲۰۲۵; al et Gurappa, ۲۰۲۵):

- **کاهش دوز تابش:** با استفاده از ابر-تفکیک‌پذیری، می‌توان دوز تابش را کاهش داد و کیفیت تصویر را با روش‌های پس‌پردازش بهبود بخشید (al et Al-Khoury, ۲۰۲۵).
- **تصویربرداری ریه:** بهبود وضوح تصاویر CT ریه برای تشخیص ضایعات ریوی و بیماری‌های تنفسی (Gurappa et al, ۲۰۲۵).
- **تصویربرداری استخوان:** مدل CL-GAN برای ابر-تفکیک‌پذیری تصاویر CT استخوان با استفاده از یادگیری برنامه‌درسی پیشرونده ارائه شده است (al et Al-Khoury, ۲۰۲۵).

- **CBCT (CT Cone-Beam):** بهبود کیفیت تصاویر CBCT در دندانپزشکی و تصویربرداری فک و صورت (al et Wang, ۲۰۲۵c).

۶.۳. توموگرافی همدوسی نوری (OCT)

در تصویربرداری OCT، به‌ویژه در دستگاه‌های قابل حمل با وضوح پایین‌تر، ابر-تفکیک‌پذیری نقش حیاتی ایفا می‌کند (Tian et al, ۲۰۲۵):

- تشخیص بیماری‌های شبکیه: مدل OCTDiff با بهبود وضوح و کیفیت تصاویر OCT قابل حمل، تشخیص بیماری‌های شبکیه را تسهیل می‌کند (Tian et al, ۲۰۲۵).
- تصویربرداری چشمی: بهبود کیفیت تصاویر OCT برای تشخیص گلوکوم، دژنراسیون ماکولا و سایر بیماری‌های چشمی (Tian et al, ۲۰۲۵).

۶.۴. سونوگرافی

در تصویربرداری سونوگرافی، ابر-تفکیک‌پذیری برای موارد زیر کاربرد دارد (al et Wang, ۲۰۲۵e):

- سونوگرافی قابل حمل: بهبود کیفیت تصاویر دستگاه‌های سونوگرافی قابل حمل با وضوح پایین.
- سونوگرافی جنین: بهبود کیفیت تصاویر سونوگرافی جنین در محیط‌های با منابع محدود.
- سونوگرافی میکروسکوپی موضع‌سازی: استفاده از SRGAN برای پس‌پردازش تصاویر سونوگرافی میکروسکوپی موضع‌سازی (al et Wang, ۲۰۲۵e).

۶.۵. سایر مودالیت‌ها

علاوه بر موارد فوق، روش‌های ابر-تفکیک‌پذیری در مودالیت‌های دیگری نیز کاربرد دارند (al et Chen, ۲۰۲۵; Gurappa et al, ۲۰۲۵):

- **PET:** بهبود وضوح تصاویر PET با استفاده از مدل DiffCode (al et Chen, ۲۰۲۵).
- تصویربرداری هیستوپاتولوژی: بهبود کیفیت تصاویر پاتولوژی برای تشخیص دقیق‌تر بیماری‌ها.
- تصویربرداری اشعه ایکس: بهبود کیفیت تصاویر قفسه سینه برای تشخیص بیماری‌های ریوی (al et Gurappa, ۲۰۲۵).

۷. چالش‌ها و محدودیت‌ها

با وجود پیشرفت‌های چشمگیر، روش‌های ابر-تفکیک‌پذیری مبتنی بر مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه با چالش‌ها و محدودیت‌های متعددی مواجه هستند.

۷.۱. چالش‌های مشترک

کمبود داده‌های آموزشی با کیفیت بالا: داده‌های تصویربرداری پزشکی با کیفیت بالا و جفت‌شده (HR-LR) محدود هستند و تهیه آنها نیازمند زمان، هزینه و تخصص بالینی است (al et Wang, ۲۰۲۵b).

تفاوت در تجهیزات و پروتکل‌های تصویربرداری: تصاویر پزشکی از مراکز مختلف با تجهیزات و پروتکل‌های متفاوت تهیه می‌شوند که منجر به شکاف در توزیع داده‌ها و کاهش عملکرد مدل‌ها در محیط‌های بالینی واقعی می‌شود (al et Wang, ۲۰۲۵b).

نیاز به قابلیت تعمیم‌پذیری: مدل‌های آموزش‌دیده بر روی جمعیت‌های خاص ممکن است در جمعیت‌های دیگر عملکرد مناسبی نداشته باشند یا آرتیفکت‌هایی تولید کنند که قابلیت اطمینان بالینی آنها را کاهش دهد (al et Wang, ۲۰۲۵b).

هزینه محاسباتی بالا: مدل‌های پخش به‌ویژه به منابع محاسباتی قابل‌توجهی برای آموزش و نمونه‌برداری نیاز دارند (Liu et al, ۲۰۲۵b).

۷.۲. چالش‌های خاص مدل‌های پخش

سرعت نمونه‌برداری پایین: مدل‌های پخش برای تولید هر تصویر به صدها یا هزاران مرحله پیمایش نیاز دارند که زمان‌بر است (Liu et al, ۲۰۲۵b). هرچند روش‌هایی مانند PFEDiff با استفاده از RDMS و کاهش مراحل نمونه‌برداری به ۵۰ مرحله، این چالش را تا حدی برطرف کرده‌اند، اما همچنان نسبت به GAN‌ها کندتر هستند (Liu et al, ۲۰۲۵b).

هزینه آموزش بالا: آموزش مدل‌های پخش نیازمند داده‌های زیاد و زمان محاسباتی طولانی است (al et Sui, ۲۰۲۵).

پیچیدگی معماری: طراحی و تنظیم معماری مدل‌های پخش پیچیده‌تر از GAN‌هاست و نیازمند تخصص بیشتری است (al et He, ۲۰۲۵b).

۷.۳. چالش‌های خاص شبکه‌های دشمن‌گونه

بی‌ثباتی در آموزش: GAN‌ها به دلیل ماهیت رقابتی خود، با نوسانات شدید در تابع هزینه و واگرایی آموزش مواجه هستند (al et Zhang, ۲۰۲۵a).

فروپاشی حالت: تولیدکننده ممکن است تنها زیرمجموعه محدودی از تنوع داده‌ها را یاد بگیرد و تنوع تصاویر تولیدشده را کاهش دهد (al et Zhang, ۲۰۲۵a).

تولید آرتیفکت: GANها ممکن است ساختارهای مصنوعی و غیرواقعی در تصاویر خروجی تولید کنند که می‌تواند به تشخیص اشتباه منجر شود (al et Zhang, ۲۰۲۵a).

نیاز به تنظیم دقیق فرارامترها: عملکرد GANها به شدت به انتخاب فرارامترها وابسته است و تنظیم آنها نیازمند آزمون و خطای فراوان است (al et Zhang, ۲۰۲۵b).

۷.۴. چالش‌های بالینی

تأیید بالینی: روش‌های ابر-تفکیک‌پذیری نیازمند تأیید بالینی گسترده در محیط‌های واقعی هستند تا اطمینان حاصل شود که تصاویر بازسازی‌شده از نظر تشخیصی معتبر هستند (al et Liu, ۲۰۲۵e).

مسائل قانونی و اخلاقی: استفاده از روش‌های مولد در تصویربرداری پزشکی با مسائل قانونی و اخلاقی از جمله مسئولیت در قبال تشخیص‌های اشتباه و حفظ حریم خصوصی بیماران همراه است (al et Wang, ۲۰۲۵a).

پذیرش بالینی: پزشکان و رادیولوژیست‌ها ممکن است نسبت به استفاده از تصاویر تولیدشده توسط هوش مصنوعی در تشخیص‌های بالینی محتاط باشند و نیازمند آموزش و آشنایی با این فناوری‌ها هستند (al et Liu, ۲۰۲۵e).

۸. جدول مقایسه روش‌های پیشرو

جدول ۱ مقایسه جامعی از روش‌های پیشرو در ابر-تفکیک‌پذیری تصاویر پزشکی بر اساس مدل پایه، مودالیت، نوآوری اصلی، مزایا و چالش‌ها ارائه می‌دهد.

جدول ۱: مقایسه روش‌های پیشرو در ابر-تفکیک‌پذیری تصاویر پزشکی

چالش‌ها	مزایا	نوآوری اصلی	مودالیت	مدل پایه	روش
پیچیدگی معماری	بزرگنمایی دلخواه، استفاده از اطلاعات چند-کنتراستی	WINRM + HMF	MRI چند-کنتراستی	پخش شرطی	IM-Diff (al et Liu, ۲۰۲۵a)
محدودیت به OCT	بهبود دینامیک واهسته‌سازی، حفظ جزئیات ظریف	MSCA + ANA	OCT قابل حمل	پخش شرطی	OCTDiff (al, ۲۰۲۵ et Tian)

نیاز به ۵۰ مرحله نمونه‌برداری	سرعت ۱۰× سریع‌تر، کاربرد در کانکتومیکس	PIEM + RDMs	D ^۳ MRI	پخش شرطی	PFEDiff (al et Liu, ۲۰۲۵b)
پیچیدگی محاسباتی	ابر-تفکیک‌پذیری کور، آگاهی از ادراک	SIF-Mamba + PBKN	MRI	پخش شرطی	MDM (al et Liu, ۲۰۲۵c)
چالش‌های GAN	پردازش دنباله‌ای، سرکوب نویز	Attention + LSTM	تصاویر D ^۳ پزشکی	GAN	LSTMAGAN (al et Zhang, ۲۰۲۵b)
چالش‌های GAN	جلوگیری از کاهش SNR، گرادین، بهبود	+ Dense Residual Attention	تصاویر پزشکی	GAN	FRDAGAN (al et Zhang, ۲۰۲۵a)
چالش‌های GAN	تمرکز بر مناطق بالینی مهم	Self/Channel/Spatial Attention	MRI	GAN	AttentionGAN (al et Liu, ۲۰۲۵e)
پیچیدگی بالا	بازسازی همه-کاره، جبران اطلاعات از دست‌رفته	+ Codebook VQ Diffusion Latent	MRI/CT/PET	پخش نهفته	DiffCode (al, ۲۰۲۵, et Chen)

جدول ۲ معیارهای ارزیابی کمی و مقادیر گزارش‌شده برای روش‌های مختلف را نشان می‌دهد.

جدول ۲: معیارهای ارزیابی کمی روش‌های پیشرو

مرجع	SSIM	(dB) PSNR	مجموعه داده	روش
al et Zhang (۲۰۲۵a)	۰.۲۸/۹۳.۸±۰/۰	۱۵.۷/۰.۰۵±۰/۳۳	Luna1۶	FRDAGAN
al et Zhang (۲۰۲۵a)	۰.۲۴/۸۸.۹±۰/۰	۱۸.۳/۲۷.۰±۰/۳۵	MRI Brain	FRDAGAN
al et He (۲۰۲۵b)	-	۶۱/۰+ بهبود SSIM	BSD1۰۰	BUFF
al et Zhang (۲۰۲۵b)	بهبود نسبت به روش‌های مقایسه	بهبود نسبت به روش‌های مقایسه	Luna1۶/BraTs۲۰۲۱	LSTMAGAN
al et Kirch (۲۰۲۵)	۹۹/۰ (۲×)	۷۷/۳۷	Clinical / IXI Brain	DisC-Diff

۹. چشم‌انداز آینده

حوزه ابر-تفکیک‌پذیری تصاویر پزشکی با استفاده از مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه در حال تحول سریع است و چندین جهت برای پژوهش‌های آینده قابل‌شناسایی است.

۹.۱. ترکیب مدل‌های پخش و GAN

ترکیب نقاط قوت مدل‌های پخش (کیفیت بالا، پایداری) و GANها (سرعت بالا، جزئیات بافتی) می‌تواند به روش‌های هیبریدی کارآمدتری منجر شود (al et Sui, ۲۰۲۵). استفاده از GANها برای نمونه‌برداری سریع از مدل‌های پخش یا استفاده از مدل‌های پخش برای بهبود کیفیت خروجی GANها، از جمله رویکردهای نویدبخش هستند.

۹.۲. مدل‌های پخش کارآمد

توسعه مدل‌های پخش با سرعت نمونه‌برداری بالاتر و هزینه محاسباتی کمتر، یکی از اولویت‌های اصلی پژوهش‌های آینده است (al et Liu, ۲۰۲۵b). رویکردهایی مانند نمونه‌بردارهای پخش پیشرفته (مانند DPM-Solver)، مدل‌های پخش در فضای نهفته (Models Diffusion Latent) و مدل‌های پخش با گام‌های کمتر، از جمله راه‌حل‌های مورد بررسی هستند (al et Chen, ۲۰۲۵).

۹.۳. یادگیری خود-نظارت و بدون-نظارت

با توجه به محدودیت داده‌های جفت‌شده (HR-LR) در تصویربرداری پزشکی، توسعه روش‌های خود-نظارت و بدون-نظارت برای ابر-تفکیک‌پذیری از اهمیت بالایی برخوردار است (al et Wang, ۲۰۲۵b). این روش‌ها می‌توانند وابستگی به داده‌های برچسب‌گذاری‌شده را کاهش دهند و قابلیت تعمیم‌پذیری مدل‌ها را افزایش دهند.

۹.۴. مدل‌های بنیادین (Models Foundation)

استفاده از مدل‌های بنیادین مانند UniSyn (al et Wang, ۲۰۲۵a) و MINIM (al et Wang, ۲۰۲۵a) که قادر به سنتز تصاویر پزشکی در مودالیت‌های مختلف هستند، می‌تواند انقلابی در ابر-تفکیک‌پذیری تصاویر پزشکی ایجاد کند. این مدل‌ها با یادگیری از حجم عظیمی از داده‌های پزشکی، قابلیت تعمیم‌پذیری بالایی دارند و می‌توانند برای وظایف مختلف ابر-تفکیک‌پذیری تطبیق داده شوند (al et Wang, ۲۰۲۵a).

۹.۵. ادغام با بالین

توسعه روش‌هایی که به‌طور یکپارچه در گردش کار بالینی ادغام شوند، از جمله ایجاد رابط‌های کاربری ساده و سیستم‌های تصمیم‌یار، می‌تواند پذیرش این فناوری‌ها را در محیط‌های بالینی تسهیل کند (al et Liu, ۲۰۲۵e). همچنین، انجام کارآزمایی‌های بالینی گسترده برای تأیید کارایی و ایمنی این روش‌ها ضروری است.

۹.۶. مدل‌های قابل تفسیر

توسعه مدل‌های قابل تفسیر که بتوانند عدم قطعیت و اطمینان خود را در مورد بازسازی‌های تولیدشده بیان کنند، می‌تواند اعتماد پزشکان را به این فناوری‌ها افزایش دهد (al et He, ۲۰۲۵b). روش‌هایی مانند BUFF که عدم قطعیت را مدل‌سازی می‌کنند، گامی در این جهت هستند (al et He, ۲۰۲۵b).

۱۰. نتیجه‌گیری

در این مقاله، به بررسی جامع روش‌های نوین تولید تصاویر مصنوعی با وضوح فوق‌بالا با استفاده از مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه برای کاربردهای پزشکی تشخیصی پرداخته شد. مدل‌های پخش شرطی با بهره‌گیری از فرایندهای انتشار و واهسته‌سازی، قادر به تولید تصاویری با کیفیت ادراکی فوق‌العاده و جزئیات دقیق هستند، در حالی که شبکه‌های دشمن‌گونه با ساختار رقابتی خود، تصاویری با بافت واقع‌گرایانه و جزئیات ظریف تولید می‌کنند.

روش‌های پیشروی بررسی‌شده در این مقاله شامل IM-Diff برای ابر-تفکیک‌پذیری MRI چند-کنتراستی در مقیاس دلخواه، OCTDiff برای بهبود تصاویر OCT قابل حمل، PFEDiff برای ابر-تفکیک‌پذیری کارآمد MRI سه‌بعدی، MDM برای ابر-تفکیک‌پذیری کور MRI، LSTMAGAN و FRDAGAN برای ابر-تفکیک‌پذیری مبتنی بر GAN، و DiffCode برای بازسازی همه-کاره تصاویر پزشکی هستند. هرکدام از این روش‌ها با نوآوری‌های خاص خود، چالش‌های موجود در حوزه ابر-تفکیک‌پذیری تصاویر پزشکی را مورد بررسی قرار داده‌اند.

نتایج نشان می‌دهد که مدل‌های پخش شرطی با وجود هزینه محاسباتی بالاتر، کیفیت و پایداری بهتری نسبت به GAN‌ها دارند، در حالی که GAN‌ها سرعت بالاتر و توانایی تولید جزئیات بافتی واقع‌گرایانه را ارائه می‌دهند. ترکیب این دو رویکرد می‌تواند راهکاری کارآمد برای تولید تصاویر پزشکی با وضوح فوق‌بالا فراهم آورد.

چالش‌های موجود شامل کمبود داده‌های آموزشی با کیفیت بالا، تفاوت در تجهیزات و پروتکل‌های تصویربرداری، هزینه محاسباتی بالا، و نیاز به تأیید بالینی گسترده است. چشم‌انداز آینده شامل توسعه مدل‌های پخش کارآمدتر، روش‌های خود-نظارت و بدون-نظارت، مدل‌های بنیادین، ادغام با بالین و مدل‌های قابل تفسیر است.

با توجه به پیشرفت‌های سریع در این حوزه، انتظار می‌رود که روش‌های ابر-تفکیک‌پذیری مبتنی بر مدل‌های پخش شرطی و شبکه‌های دشمن‌گونه در آینده نزدیک به‌عنوان ابزارهای استاندارد در گردش کار بالینی پذیرفته شوند و نقش مهمی در بهبود تشخیص، درمان و پایش بیماری‌ها ایفا کنند.

منابع

۱. Al-Khoury, Y., Figueiredo, C .P., Therkildsen, J., Finzel, S., & Waungana, T .H . (2025). (CL-GAN :A progressive curriculum learning approach for bone CT super-resolution .*arXiv preprint*.
۲. Chen, H., Yang, Z., Hou, H., Zhang, H., Wei, B., Zhou, G., & Xu, Y). ۲۰۲۵ .(All-in-One Medical Image Restoration with Latent Diffusion-Enhanced Vector-Quantized Codebook Prior .In *Proceedings of Medical Image Computing and Computer Assisted Intervention – MICCAI ۲۰۲۵*) Vol .LNCS ۱۵۹۷۵, pp .۶۷-۷۷ .(Springer.
۳. Dong, C., Loy, C .C., He, K., & Tang, X) .۲۰۱۴ .(Learning a deep convolutional network for image super-resolution .In *European Conference on Computer Vision*) ECCV) (pp .۱۸۴-۱۹۹ .(Springer.
۴. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y) .۲۰۱۴ .(Generative adversarial nets .In *Advances in Neural Information Processing Systems*) *NeurIPS*) (Vol .۲۷.
۵. Gurappa, S., Satharasi, T., Hariprasad, Y., & Iyengar, S .S) .۲۰۲۵ .(MedSR-Vision : Deep Learning Framework for Multi-Domain Medical Image Super-Resolution . *arXiv preprint*.
۶. Hassan, E., El-Rashidy, N., & Elbedwehy, S) .۲۰۲۵ .(Exploring the frontiers of image super-resolution :a review of modern techniques and emerging applications .*Neural Computing & Applications*, ۳۷)۲۲۶, ۱۷۹۱۳.
۷. He, Z., Zhang, S., Hu, R., Shen, Y., & Zhang, Y) .۲۰۲۵a .(BUFF :Bayesian Uncertainty Guided Diffusion Probabilistic Model for Single Image Super-Resolution . *Proceedings of the AAAI Conference on Artificial Intelligence*, ۳۹)۴۶, ۳۴۷۴-۳۴۸۲.
۸. He, Z., Zhang, S., Hu, R., Shen, Y., & Zhang, Y) .۲۰۲۵b .(Bayesian uncertainty guided diffusion probabilistic model for single image super-resolution .*arXiv preprint arXiv:۲۵۰۴.۰۳۴۹۰*.
۹. Ho, J., Jain, A., & Abbeel, P) .۲۰۲۰ .(Denoising diffusion probabilistic models .In *Advances in Neural Information Processing Systems*) *NeurIPS*) (Vol .۳۳, pp . ۶۸۴۰-۶۸۵۱).
۱۰. Kirch, S., et al) .۲۰۲۵ .(Disentangled Conditional Diffusion Models for Multi-Contrast MRI Super-Resolution .*arXiv preprint*.

۱۱. Liu, L., et al) .۲۰۲۵a .(IM-Diff :Implicit Multi-Contrast Diffusion Model for Arbitrary Scale MRI Super-Resolution .*IEEE Journal of Biomedical and Health Informatics*, ۲۹(۶), ۴۲۰۰-۴۲۱۲.
۱۲. Liu, L., et al) .۲۰۲۵b .(Prior feature efficient diffusion model for ۳D MRI image super-resolution improving brain connectomics analysis .*Expert Systems with Applications*.
۱۳. Liu, L., et al) .۲۰۲۵c .(Mamba-Enhanced Diffusion Model for Perception-Aware Blind Super-Resolution of Magnetic Resonance Imaging .*IEEE Journal of Biomedical and Health Informatics*, ۳۰(۴), ۳۳۵۶-۳۳۶۸.
۱۴. Liu, L., et al) .۲۰۲۵d .(ICDSR :Integrated Conditional Diffusion Model for Single Image Super-Resolution .*IEEE Transactions on Multimedia*, ۲۸, ۱۳۰۲-۱۳۱۳.
۱۵. Liu, L., et al) .۲۰۲۵e .(AttentionGAN Based Super-Resolution for Enhanced Diagnostic Accuracy in Magnetic Resonance Imaging .In *IEEE Conference Proceedings*.
۱۶. Liu, L., et al) .۲۰۲۵f .(Transform Domain Based GAN with Deep Multi-Scale Features Fusion for Medical Image Super-Resolution .*Electronics*, ۱۴(۱۸), ۳۷۲۶.
۱۷. Sui, J., et al) .۲۰۲۵ .(Adaptive Semantic-Enhanced Denoising Diffusion Probabilistic Model for Remote Sensing Image Super-Resolution .*IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
۱۸. Tian, Y., McCarthy, A., Gomide, G., Liddle, N., Golebka, J., Chen, R., Liebmann, J., & Thakoor, K) .۲۰۲۵ .(OCTDiff :Bridged Diffusion Model for Portable OCT Super-Resolution and Enhancement .In *Advances in Neural Information Processing Systems*) *NeurIPS*.
۱۹. Wang, X., et al) .۲۰۲۵a .(UniSyn :A Generative Foundation Model for Universal Medical Image Synthesis across MRI, CT and PET .In *Proceedings of Medical Image Computing and Computer Assisted Intervention - MICCAI ۲۰۲۵*.
۲۰. Wang, X., et al) .۲۰۲۵b .(Conditional Diffusion Model for Abdominal CT Image Synthesis .In *IEEE International Symposium on Biomedical Imaging*) *ISBI*.
۲۱. Wang, X., et al) .۲۰۲۵c .(Deep learning for dentomaxillofacial cone-beam computed tomography image quality enhancement :A pilot study .*Korean Journal of Radiology*.
۲۲. Wang, X., et al) .۲۰۲۵d .(Advanced Cardiac MRI :Integrating AI and Machine Learning for Post Imaging Reconstruction .*Current Treatment Options in Cardiovascular Medicine*.

۲۳. Wang, X., et al) .۲۰۲۵e .(Resolution Enhancement in Ultrasound Localization Microscopy using a Super-Resolution Generative Adversarial Network .In *IEEE International Ultrasonics Symposium*)IUS.(
۲۴. Zhang, Q., Min, B., Hang, Y., Chen, H., & Qiu, J) .۲۰۲۵a .(Fusing residual dense and attention in generative adversarial networks for super-resolution of medical images .*Quantitative Imaging in Medicine and Surgery*, ۱۵)۶۷, ۵۰۴۷-۵۰۵۹.
۲۵. Zhang, Q., et al) .۲۰۲۵b .(Super-resolution of ۳D medical images by generative adversarial networks with long and short-term memory and attention .*Scientific Reports*, ۱۵, ۲۰۸۲۸.