



Background Subtraction in X-ray Angiography Images Using Image Inpainting via Deep Learning

Akhoondi, Fateme¹ / Almasganj, Farshad^{2*}

¹ - Ph.D. Student, Bioelectric, Biomedical engineering, Amirkabir University of Technology, Tehran, Iran

² - Associate Professor, Biomedical engineering, Amirkabir University of Technology, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2025.2048672.1941

Received: 21/12/2024

Revised: 23/2/2024

Accepted: 25/2/2025

KEYWORDS

*X-ray angiography
coronary arteries
deep learning
contrast agent
Frangi filter
DeepFillv2-Grayscale*

ABSTRACT

In X-ray angiography imaging, one of the major challenges that cardiovascular specialists face is the unwanted shadows that appear from stationary and moving organs within the chest during a sequence of recorded images. These shadows reduce the quality of the images and make it harder for specialists to diagnose artery blockages. Several methods have been developed to address this issue; however, many of them require processing all frames of an input sequence, which is time-consuming. Moreover, the output of many of these methods still contains a significant amount of shadow, and the quality of the coronary arteries in the corrected images is not always satisfactory.

In this study, the Frangi filter is first used to detect the coronary arteries and remove them from the image frame containing the contrast agent. Next, the regions of the arteries are represented as a mask image, along with the frame containing the contrast agent and the closest frame without the contrast agent. These are provided as input to the deep learning model, DeepFillv2-Grayscale. This advanced network is designed to reconstruct the missing parts of the images. In this study, a specific version of this network, which operates on grayscale images, was trained specifically on X-ray angiography images.

In the final stage, the reconstructed background image is subtracted from the frame containing the contrast agent, resulting in improved images of the arteries with reduced shadows. The proposed approach can effectively reduce processing time compared to traditional methods. According to SSIM and Precision metrics, the proposed method achieves values of 0.96 and 0.97, respectively, showing superiority over well-known advanced methods such as FPCP-RPCA, OTS-RPCA, DECOLOR, and OSTD.



حذف پس‌زمینه در تصاویر ایکس-ری آنژیوگرافی با استفاده از بازسازی نواحی مفقود تصاویر توسط یادگیری عمیق آخوندی، فاطمه^۱ / الماس گنج، فرشاد^{۲*}

^۱ - دانشجوی دکترا، بیوالکتریک، مهندسی پزشکی، صنعتی امیرکبیر، تهران، ایران

^۲ - دانشیار، بیوالکتریک، مهندسی پزشکی، صنعتی امیرکبیر، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2025.2048672.1941

پذیرش: ۱۴۰۳/۱۲/۷

بازنگری: ۱۴۰۳/۱۲/۵

ثبت در سامانه: ۱۴۰۳/۱۰/۱

چکیده

واژه‌های کلیدی

در تصویربرداری ایکس‌ری آنژیوگرافی، یکی از چالش‌های اساسی که متخصصان قلب و عروق با آن روبرو هستند، سایه‌های ناخواسته‌ای است که از اعضای ثابت و متحرک داخل قفسه سینه در دنباله‌ی قاب‌های^۱ تصویری ضبط شده ظاهر می‌شود. این سایه‌ها کیفیت تصاویر را کاهش می‌دهند و تشخیص گرفتگی رگ‌ها را برای متخصصین سخت‌تر می‌کنند. برای حل این مشکل، روش‌هایی ابداع شده‌است. ولی بسیاری از آنها مجبور هستند تمامی قاب‌های یک دنباله ورودی را پردازش کنند و این زمان زیادی می‌طلبد. در عین حال خروجی بسیاری از این روش‌ها هنوز حاوی بخش زیادی از این سایه‌ها است و کیفیت رگ‌ها در تصاویر اصلاح شده هم همیشه راضی‌کننده نیست. در این تحقیق، ابتدا از فیلتر Frangi برای تشخیص عروق کرونری و حذف آنها از قاب تصویری حاوی ماده‌ی حاجب استفاده می‌شود. در ادامه، نواحی رگ‌ها به شکل یک تصویر ماسک، به همراه قاب تصویری حاوی ماده‌ی حاجب و همچنین نزدیک‌ترین قاب بدون ماده حاجب به آن، به ورودی مدل عمیق deepfillv2-grayscale داده می‌شود. این شبکه پیش‌سرفته، برای بازسازی بخش‌های حذف شده از تصاویر طراحی شده است. در این تحقیق گونه‌ای از این شبکه را که بر روی تصاویر مقیاس خاکستری عمل می‌کند بکار گرفتیم و بطور خاص بر روی تصاویر ایکس‌ری آنژیوگرافی تعلیم تکمیلی دادیم. در مرحله‌ی آخر تصویر پس‌زمینه‌ی بازسازی شده، از قاب تصویری حاوی ماده‌ی حاجب، کم می‌شود تا تصاویر بهتری از عروق با کاهش سایه‌ها به دست آید. رویکرد پیشنهادی می‌تواند به طور مؤثری زمان پردازش را نسبت به روش‌های سنتی بهبود بخشد. روش پیشنهادی این تحقیق، بر اساس معیارهای SSIM و Precision به ترتیب به مقادیر ۰,۹۶ و ۰,۹۷ دست می‌یابد که در مقایسه با روش‌های پیش‌سرفته شناخته شده مانند FPCP-OSTD و DECOLOR، OTS-RPCA، RPCA برتری نشان می‌دهد.

ایکس‌ری آنژیوگرافی
رگ‌های قلب
یادگیری عمیق
ماده‌ی حاجب
فیلتر Frangi
deepfillv2-grayscale

^۱ Frames

۱- مقدمه

تصویربرداری ایکس ری آنژیوگرافی^۲ (XRA) به عنوان استاندارد طلایی برای تشخیص بیماری‌های شریان کرونری^۳ (CAD) شناخته می‌شود [۱]. در تصاویر آنژیوگرافی، سایه‌های متعددی از بافت‌ها مانند سایه‌های اندام تنفسی و استخوان‌های قفسه‌ی سینه وجود دارند که روی شریان‌های کرونری حاوی ماده‌ی حاجب، قرار می‌گیرند. این سایه‌ها می‌توانند تشخیص عروق را دشوار کنند و باعث می‌شوند متخصصان قلب و عروق مجبور شوند مقدار بیشتری از ماده‌ی حاجب را تزریق کنند و بیماران را در معرض دوز بالاتری از اشعه‌ی ایکس در حین انجام عمل آنژیوگرافی قرار دهند.

یک تکنیک قدرتمند برای نمایان تر کردن عروق خونی در تصاویر XRA، آنژیوگرافی با تفریق دیجیتالی^۴ [۲] (DSA) است که برای فریم‌های ویدئویی به دست آمده از اشعه‌ی ایکس طراحی شده‌است. این تکنیک کارآمد بر پایه‌ی یک فرایند کشف پس‌زمینه‌ی پیشین عمل می‌کند. در تصویربرداری DSA، ابتدا یک دنباله از تصاویر اشعه‌ی ایکس از منطقه‌ی هدف در بدن گرفته می‌شود و در همین زمان، مقدار مناسبی از ماده حاجب به رگ‌های آن ناحیه تزریق می‌شود. در این مقاله، تصاویری که قبل از تزریق ماده حاجب گرفته می‌شوند و در آن‌ها رگ‌های قلب قابل مشاهده نیستند، به عنوان فریم‌های ماسک لحاظ می‌شوند. همچنین تصاویر بعدی که ماده‌ی حاجب در آن‌ها وجود دارد، به عنوان فریم‌های کنتراست معرفی می‌شوند. در ادامه‌ی روند DSA فریم ماسک از فریم کنتراست کم می‌شود تا ساختارهای پس‌زمینه حذف شده و دید رگ‌ها بهتر شود.

با این حال، این روش در ویدئوهای XRA به دلیل حرکت پیچیده سایه‌های اعضای مختلف بدن در جهات مختلف، به راحتی قابل استفاده نیست. هیچ یک از فریم‌های ماسک دقیقاً پس‌زمینه‌ی فریم‌های کنتراست بعدی نیستند. بنابراین، هدف این مقاله بازسازی و حذف سایه‌های پس‌زمینه از دنباله‌های XRA برای مشاهده‌ی واضح‌تر شریان‌های کرونری و ایجاد شرایط بهتر برای تشخیص تنگی این شریان‌ها است.

برای این منظور، در این تحقیق یک روش یادگیری عمیق سرتاسری پیشنهاد و بهینه شده‌است. این روش به طور مؤثر از تکنیک ترمیم تصویر^۵ [۳] استفاده می‌کند. اطلاعات کمکی از سایر نواحی به جز رگ در فریم کنتراست و نزدیک‌ترین پس‌زمینه به این فریم (در فاز تعلیم) می‌تواند در بازسازی

خودکار نواحی عروق حاوی ماده‌ی حاجب پس از حذف این نواحی نقش داشته باشند.

روش پیشنهادی ابتدا سایه‌های ناشی از جریان ماده‌ی حاجب در داخل رگ‌ها را از فریم کنتراست با استفاده از فیلتر Frangi [4] تشخیص می‌دهد و سپس این نواحی را حذف می‌کند. در ادامه از اطلاعات فریم ماسک، فریم کنتراست که عروق حاوی ماده‌ی حاجب در آن‌ها با کمک فیلتر Frangi ماسک شده و همچنین نزدیک‌ترین فریم ماسک که به فریم کنتراست وجود دارد برای fine-tuning شبکه‌ی deepfillv2-grayscale [۵] با هدف بازسازی نواحی خالی در فریم کنتراست استفاده می‌شود. به این ترتیب، مناطق حذف شده در فریم کنتراست دوباره پر می‌شوند تا تصویر پس‌زمینه‌ی ترمیم‌شده برای مرحله‌ی بعدی بازسازی شود.

این روش باعث کاهش زمان پردازش و بهبود کیفیت تصاویر آنژیوگرافی می‌شود و به تشخیص بهتر مشکلات شریانی کمک می‌کند.

در ادامه، در این روند، بخش رگ‌ها از تصویر حذف می‌گردد و تصویر ناقص می‌شود. سپس با استفاده از شبکه‌ی deepfillv2-grayscale، بازسازی بخش‌های خالی تصویر انجام شده و پس‌زمینه بازسازی می‌شود. این ساختار برای تطبیق بهتر با ماهیت و چگونگی حرکت عروق کرونری قلب و حرکت ماده‌ی حاجب داخل آن طراحی و پیشنهاد شده‌است. روند کلی این الگوریتم در شکل ۱ نمایش داده شده‌است.

با توجه به توضیحاتی که تا اینجا ارائه شد، مهم‌ترین نوآوری‌های این تحقیق به صورت زیر است:

طراحی سیستمی که در چند مرحله و با استفاده از یادگیری عمیق پس‌زمینه‌ی قاب‌های تصویری ایکس-ری آنژیوگرافی را حذف می‌کند.

آماده سازی و برچسب دهی دادگانی بومی از ویدئوهای ایکس-ری آنژیوگرافی.

استفاده از شبکه‌ی deepfillv2-grayscale و تطبیق آن به کاربرد این تحقیق با تعلیم دقیق آن بر روی دادگان آنژیوگرافی بومی که توسط خودمان جمع آوری و آماده سازی شده است.

۲-۱- مروری بر کارهای پیشین

۱-۲-۱- فیلتر فرنگی

برای استخراج عروق در تصاویر آنژیوگرافی یک روش متداول استفاده از فیلتر فرنگی [۴] است. فیلتر Frangi یک تکنیک

^۲ digital subtraction angiography

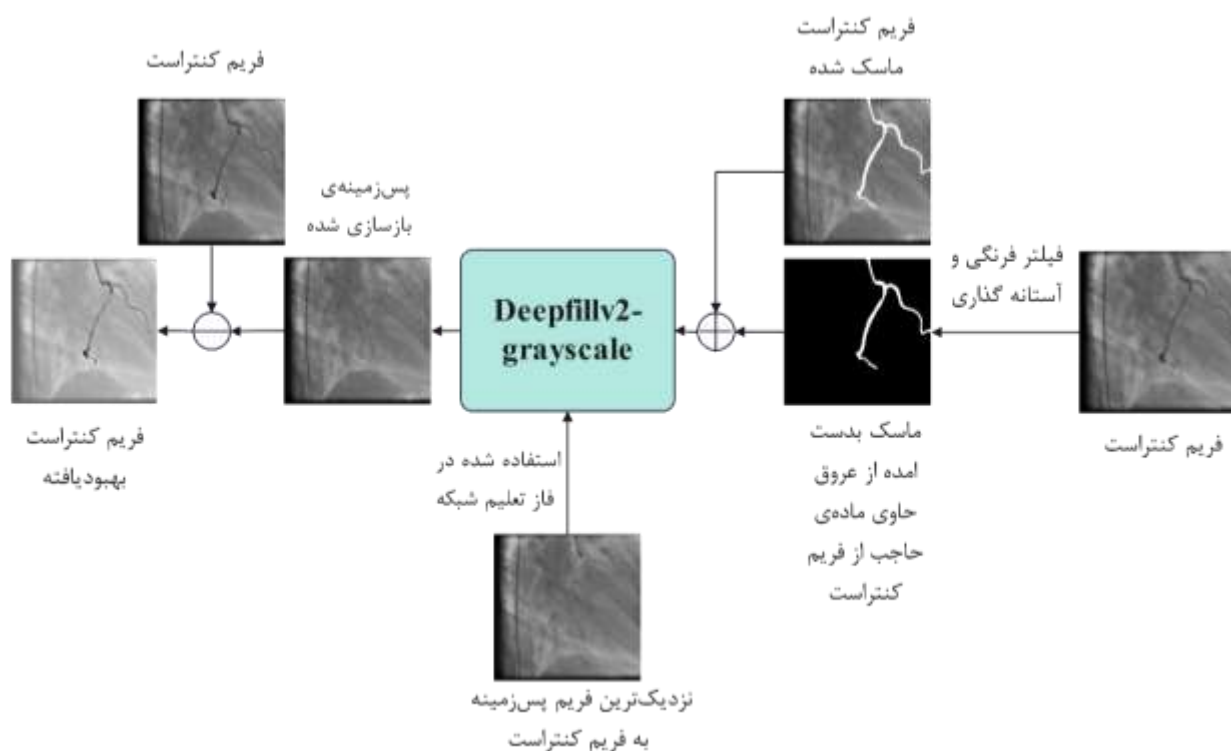
^۵ image inpainting

^۲ X-ray angiography

^۳ coronary artery diseases

تا رگ‌های خونی را بهتر شناسایی و ارزیابی کنند. با پیشرفت‌های چشمگیر یادگیری عمیق می‌توان از شبکه‌های جایگزینی برای روش Frangi، جهت تشخیص نواحی رگ‌ها استفاده نمود.

شناخته‌شده برای بهبود و جداسازی ساختارهای شبیه به رگ در تصاویر پزشکی است. این فیلتر در حوزه‌های مختلفی از جمله آنژیوگرافی‌های کرونری، استخراج رگ‌های شبکه‌ی [۶] و بهبود رگ‌های ریه [۷] مورد استفاده قرار گرفته‌است. به‌طور خاص، در آنژیوگرافی‌های کرونری، فیلتر Frangi به پزشکان کمک می‌کند



شکل ۱: بازسازی تصویر پس‌زمینه با کمک *deepfillv2-grayscale* و تفریق آن از تصویر کنتراست

توالی‌های XRA استفاده شده‌است. علاوه بر این، تفریق پس‌زمینه برای بهبود نمایش عروق در فریم‌های کنتراست که پس‌زمینه‌هایشان بازسازی و حذف شده، استفاده می‌شود. در ادامه، مقالات مربوط به این دو حوزه‌ی تحقیقاتی بررسی شده‌است.

۲-۲-۱- روش‌های سنتی و یادگیری عمیق برای ترمیم تصویر

روش‌های ترمیم تصویر می‌توانند به دو دسته‌ی اصلی تقسیم‌بندی شوند: روش‌های سنتی (مبتنی بر patch) و روش‌های مبتنی بر یادگیری عمیق. برخی محققان از تکنیک‌های تطابق دهی patch سنتی استفاده کرده‌اند. قرار دادن نزدیک‌ترین patch مشابه در ناحیه‌ی مشخص شده برای ترمیم تصاویر ساده بسیار موفق عمل کرده‌اند اما در تصاویر با پیچیدگی

به‌طور دقیق‌تر فیلتر Frangi بر اساس تجزیه و تحلیل ساختار محلی تصویر با استفاده از ماتریس هسین^۶ عمل می‌کند. این ماتریس اطلاعاتی درباره‌ی انحناهای تصویر ارائه می‌دهد که برای شناسایی عروق ضروری است. با استفاده از مقادیر ویژه این ماتریس، فیلتر می‌تواند جهت و شدت عروق را شناسایی کند [۴].

همچنین فیلتر Frangi با استفاده از مقادیر ویژه، نسبت‌هایی را محاسبه می‌کند که به آن میزان عروقی^۷ گفته می‌شود. این میزان عروقی به تشخیص و تقویت عروق در تصاویر کمک کرده و باعث افزایش کنتراست عروق نسبت به پس‌زمینه می‌شود. در ادامه، برخی از مطالعات پیشین با دو هدف مرور می‌شوند که مرتبط با نوآوری‌ها و ساختارهای اصلی مقاله‌ی فعلی هستند: ترمیم تصویر و تفریق پس‌زمینه^۸. ترمیم تصویر رویکرد اصلی این مقاله برای بازسازی پس‌زمینه‌های فریم‌های کنتراست در

^۸ Background subtraction

^۶ Hessian

^۷ vesselness measure

متخاصم Wasserstein برای بهبود استحکام و سرعت آموزش هستند [۱۴، ۱۵]. چنین بهبودهایی به ثبات و سرعت بیشتر در آموزش کمک می‌کند و در نهایت زمان کل آموزش را کاهش می‌دهد. با این حال، ادغام استراتژی‌های پیچیده ممکن است نیاز به تنظیم دقیق داشته باشد تا از بیش‌برازش یا ناپایداری در طول آموزش شبکه جلوگیری شود.

همچنین گروهی از محققان یک روش ترمیم تصویر با وضوح فوق‌العاده را با مکانیزم جدیدی به نام تجمیع باقیمانده زمینه‌ای^{۱۱} معرفی کردند [۱۶]. این رویکرد نوآورانه هدفش افزایش وضوح و جزئیات مناطق ترمیم شده بود، اما نیاز به منابع محاسباتی قابل توجهی داشت که می‌توانست دسترسی به آن را برای برخی از برنامه‌ها محدود کند.

برای توسعه‌ی روش موجود، محققان یک روند کاری را معرفی کردند که از الگوی اول ساختار، بعد جزئیات^{۱۲} پیروی می‌کند. این رویکرد با مولدی به شکل هرم تکمیل می‌شود که شامل زیرمولدهای متراکم است و از تکنیک‌های هنری الهام می‌گیرد [۱۷]. این پیشرفت از پایین به بالا، بازسازی تدریجی و منسجم تصاویر ورودی را تسهیل می‌کند. با این حال، ممکن است نیاز به مدیریت دقیق گذار بین لایه‌ها برای اطمینان از اینکه خروجی نهایی همچنان منسجم و بصری جذاب باقی بماند، داشته باشد. مقاله‌ی deepfillv2 به بررسی یک رویکرد نوآورانه برای ترمیم تصاویر می‌پردازد که از ماسک‌های آزاد و راهنمایی‌های کاربر استفاده می‌کند. این روش بر پایه‌ی کانولوشن دروازه‌ای^{۱۳} طراحی شده است [۵]. این نوع کانولوشن به شبکه‌های عصبی این امکان را می‌دهد تا ویژگی‌های دینامیکی را برای هر کانال و مکان فضایی یاد بگیرند. با این رویکرد، سیستم قادر است تا کیفیت بالاتری در ترمیم تصاویر ارائه دهد و سازگاری رنگ بهتری را نسبت به روش‌های قبلی فراهم کند. همچنین، در این مقاله GAN مبتنی بر patch (SN-PatchGAN) معرفی شده است. این نوع GAN به طور خاص برای ترمیم تصاویر با ماسک‌های آزاد طراحی شده است و نتایج قابل توجهی را به نمایش می‌گذارد. این روش دارای مزایای قابل توجهی است، از جمله کیفیت بالای ترمیم و انعطاف‌پذیری در استفاده از ماسک‌های آزاد، که آن را برای کاربردهای متنوع مناسب می‌سازد. علاوه بر این، استفاده از داده‌های بدون برچسب فرآیند آموزش را تسهیل می‌کند و زمان مورد نیاز برای آماده‌سازی داده‌ها را کاهش می‌دهد. با این حال، برخی معایب نیز وجود

بالا دچار مشکل می‌شوند [۸]. با توجه به این نقص، پژوهشگران در مطالعه‌ای دیگر به بررسی ادغام تصاویر نامتجانس از طریق یک تکنیک سنتز مبتنی بر patch می‌پردازند [۹]. این رویکرد ناهماهنگی‌های بین تصاویر متعدد را برای ایجاد یک ترکیب دقیق تر و منسجم تر حل می‌کند. اما مطابق با کار قبلی همچنان مشکلاتی در نواحی مرزی و یافت‌های غیر یکنواخت در مرزهای ترمیم شده دارند.

به‌طور کلی الگوریتم‌های مبتنی بر patch در پر کردن حفره‌های بزرگ در تصاویر طبیعی و بافت‌های یکنواخت مؤثرند، اما در مناطقی با تنوع بافتی یا محتوایی قابل توجه، ضعف دارند.

در زمینه‌ی یادگیری عمیق، کدگذارهای زمینه‌ای^۹ از شبکه‌های عصبی کانولوشنی برای بازسازی محتوا از مناطق حذف‌شده بر اساس پیکسل‌های اطراف استفاده می‌کنند [۱۰]. اگرچه کدگذارهای زمینه‌ای پیشرفت قابل توجهی در ترمیم تصویر محسوب می‌شوند، اما هنوز به شدت به زمینه‌ی تصویر و اطلاعات اطراف آن ناحیه وابسته‌اند و ممکن است در مواجهه با تصاویر پیچیده که الگوهای پیچیده یا محتوای متنوعی دارند، با مشکل مواجه شوند. برای مقابله با این مشکل، در مطالعه‌ای دیگر از شبکه‌ی عصبی تماماً کانولوشنی استفاده شده است تا به تکمیل یکنواخت تصویر، هم به صورت محلی و هم به صورت کلی دست یافت [۱۱]. همچنین در مقاله‌ی دیگری این تکنیک با کمک کانولوشن جزئی به همراه یک تابع بروزسانی ماسک بهبود داده شده است [۱۲]. این روش دقت ترمیم را افزایش می‌دهد، اما ممکن است به طور کامل از اطلاعات مناطق اطراف استفاده نکند. در ادامه، تحولات بیشتری در شبکه‌های مولد ترمیم تصویر در رویکردهای بعدی مشاهده می‌شود که کارایی و اثر بخشی آموزش را افزایش می‌دهند. محققان یک روش نوآورانه را معرفی می‌کنند که از مدل‌های مولد عمیق برای سنتز ساختارهای جدید تصویر استفاده می‌کند و در عین حال از ویژگی‌های اطراف تصویر به عنوان مرجع‌های اولیه استفاده می‌کند [۱۳]. ویژگی کلیدی این رویکرد لایه‌ی توجه زمینه‌ای است که بر روی patch‌های مرتبط در مکان‌های مکانی دور متمرکز می‌شود. با این حال، وابستگی به ویژگی‌های فضایی دور می‌تواند فرآیند آموزش مدل را پیچیده کند و ممکن است چالش‌هایی را در حفظ همگنی فضایی ایجاد کند.

در ادامه، پژوهشگران روش‌هایی را پیشنهاد دادند که شامل بهبودهای کیفیت شبکه، با استفاده از شبکه‌های مولد

^{۱۲} structure first, detail next^{۱۳} Gated Convolution^۹ Context Encoders^{۱۰} Context Encoders^{۱۱} Contextual Residual Aggregation

آن‌ها را از تصویر اصلی کسر کرد تا ویژگی‌ها و ساختارهای خاص در تصویر جدا و ایزوله شوند.

یکی از چالش‌های اصلی در این روش‌ها، نیاز به پردازش هم‌زمان تمام فریم‌های یک ویدیوی سینوآنژیوگرام یا اکثریت فریم‌های این ویدئوهاست. این مسئله منجر به زمان پردازش طولانی می‌شود. به دلیل وجود این مشکل، این روش‌ها عموماً نمی‌توانند در برنامه‌های برخط برای بهبود کیفیت ویدیوهای آنژیوگرافی استفاده شوند. علاوه بر این، خروجی‌های حاصل از این روش‌ها در حذف ساختارهای غیرمرتبط با مشکلاتی مواجه می‌شوند.

۲- روش‌ها

۲-۱- تشخیص عروق با استفاده از فیلتر Frangi

در این بخش مقاله، به بررسی الگوریتم پیشنهادی برای استخراج عروق کرونری در تصاویر آنژیوگرافی با استفاده از شبکه‌های عصبی عمیق پرداخته می‌شود.

در گام اول از فیلتر Frangi برای تشخیص عروق استفاده می‌شود. فیلتر Frangi بر روی فریم کنتراست اعمال می‌شود و ساختارهای رگ مانند استخراج می‌شوند. سپس با استفاده از آستانه‌گذاری تصویر ماسک به‌دست آمده از این عروق در خروجی نمایش داده می‌شوند. سپس با کمک این ماسک به‌دست آمده، تصاویر کنتراست ناقص می‌شود (به این معنا که نواحی عروق حذف می‌شوند). بنابراین این تصاویر نیاز به ترمیم پیدا می‌کنند تا با کمک شبکه‌ی `deepfillv2-grayscale` ترمیم شوند.

۲-۱-۱- معماری شبکه‌ی `deepfillv2-grayscale`

شبکه‌ی `deepfillv2-grayscale` [۵] یک تکنیک پیشرفته در زمینه‌ی ترمیم تصاویر است که از مدل‌های یادگیری عمیق برای بازسازی بخش‌های حذف‌شده یا تخریب‌شده‌ی یک تصویر استفاده می‌کند. `deepfillv2-grayscale` به عنوان یک نسخه‌ی بهبود یافته از مدل اولیه `deepfillv` شناخته می‌شود و از شبکه‌های عصبی کانولوشنی برای انجام وظایف ترمیم و بازسازی تصویر بهره می‌برد. یکی از ویژگی‌های کلیدی این مدل، استفاده از مکانیسم توجه زمینه‌ای^{۲۲} است که به مدل اجازه می‌دهد تا بر روی نواحی مرتبط تصویر تمرکز کند و به این ترتیب بخش‌های حذف شده را با دقت بیشتری پر کند.

دارد. از جمله می‌توان به پیچیدگی محاسباتی بالای کانولوشن دروازه‌ای و GAN اشاره کرد که نیاز به منابع محاسباتی زیادی دارند. همچنین، وابستگی به تنوع و کیفیت داده‌های آموزشی می‌تواند بر کیفیت نتایج تأثیر بگذارد و در صورت کمبود داده‌های متنوع، محدودیت‌هایی ایجاد کند.

۳-۲-۱- مرور روش‌های موجود برای حذف پس زمینه

در ادامه، چندین روش مختلف برای تفکیک پس‌زمینه از پیش‌زمینه در تصاویر پزشکی، به‌ویژه در تصاویر سینوآنژیوگرام بررسی شده‌است.

حذف پس‌زمینه مبتنی بر patch^{۱۴} (PABSM) روشی کارآمد در حذف پس‌زمینه‌ی تصاویر XRA است [۱۸]. در این روش، پس‌زمینه‌ی تصویر با استفاده از رویکرد مبتنی بر patch‌های محلی^{۱۵} مدل‌سازی می‌شود. این روش توانایی دارد تا به‌طور تطبیقی^{۱۶} ویژگی‌های پس‌زمینه را مدل‌سازی کند و برای پس‌زمینه‌های غیرایستا (مثل تغییرات تدریجی نور) و پس‌زمینه‌هایی که تغییرات مداوم دارند، عملکرد مناسبی را ارائه دهد. این روش به‌ویژه برای مسائل پیچیده‌تر مانند تغییرات نور یا پس‌زمینه‌های متغیر در تصاویر سینوآنژیوگرام مناسب است. روش‌های مبتنی بر ویژگی‌ها^{۱۷}، دسته‌ی دیگری برای حذف پس‌زمینه‌ها است [۱۹، ۲۰]. این روش‌ها از مقایسه‌ی patch‌های بین تصاویر زنده^{۱۸} و ماسک برای حذف پس‌زمینه استفاده می‌کنند. محققان در مطالعه‌ی دیگر از تکنیک تطبیق الگو با استفاده از معیار شباهت برای تطابق patch‌ها استفاده می‌کنند. پس از این تطبیق، تصویر ماسک از تصویر زنده کسر می‌شود تا تقویت رگ‌های خونی انجام شود [۲۱]. با این حال، این روش‌ها معمولاً در حذف ساختارهایی مانند اسکلت و دیافراگم مشکل دارند.

همچنین روش‌های جداسازی لایه‌ها^{۱۹}، دسته‌ی دیگری برای تفکیک پس‌زمینه از پیش‌زمینه است [۲۲، ۲۳]. این روش‌ها از تحلیل مولفه‌های اصلی (PCA^{۲۰}) و مشتقات مختلف آن برای تفکیک پس‌زمینه در تصاویر سینوآنژیوگرام استفاده می‌کنند. این روش‌ها فرض می‌کنند که سینوآنژیوگرام‌ها از لایه‌های کم رتبه و تنک^{۲۱} تشکیل شده‌اند و یک تابع هدف به‌طور تدریجی در طول یک سری از تصاویر بهینه می‌شود تا لایه‌های تنک را استخراج کند. پس از به‌دست آوردن این لایه‌های تنک، می‌توان

^{۱۹} Layer separation methods

^{۲۰} principal component analysis

^{۲۱} low-rank and sparse

^{۲۲} Context attention

^{۱۴} Patch-based Adaptive Background Subtraction Method

^{۱۵} local phase-based method

^{۱۶} adaptive

^{۱۷} Feature-based methods

^{۱۸} live

در سه رابطه‌ی بالا ابتدا، مقادیر خروجی گیت با استفاده از یک فیلتر کانولوشنی W_g محاسبه می‌شود. سپس ویژگی‌ها با فیلتر دیگری W_f استخراج می‌شوند. در نهایت، خروجی نهایی $O_{y,x}$ با ترکیب ویژگی‌ها و مقادیر خروجی گیت محاسبه می‌شود. در این سه فرمول با تابع σ اطمینان حاصل می‌کند که مقادیر خروجی گیت بین ۰ و ۱ قرار دارند و ϕ می‌تواند هر تابع فعال‌سازی دیگری باشد [۵].

این روش به شبکه اجازه می‌دهد تا به طور دینامیک تصمیم بگیرد که کدام ویژگی‌ها مهم‌تر هستند و باید در مرحله‌ی بعدی پردازش شوند. این کار با استفاده از یک ماسک نرم انجام می‌شود که به طور خودکار از داده‌ها یاد گرفته می‌شود. بنابراین gated convolution قادر است تا ویژگی‌ها را بر اساس زمینه و اطلاعات موجود تطبیق دهد. این تکنیک به ویژه در مدل‌هایی مانند deepfill و Gated CNNs برای پر کردن نواحی حذف‌شده در تصاویر کاربرد دارد و می‌تواند منجر به نتایج بهتری نسبت به کانولوشن‌های معمولی شود [۵].

در لایه‌ی میانی شبکه نیز هشت لایه‌ی کانولوشن دیگر وجود دارد که به یادگیری ویژگی‌های پیچیده‌تر کمک می‌کنند. برخی از این لایه‌ها دارای dilation هستند که به افزایش میدان ادراکی شبکه کمک می‌کند.

dilation یک تکنیک در پردازش تصویر است که برای افزایش میدان ادراکی شبکه‌های عصبی بدون افزایش تعداد پارامترها یا ابعاد تصویر استفاده می‌شود. در لایه‌های کانولوشن معمولی، هر کرنل بر روی پیکسل‌های مجاور اعمال می‌شود، اما در dilation، فاصله‌ی بین پیکسل‌ها در کرنل افزایش می‌یابد. این روند با اضافه کردن فاصله‌های خالی بین عناصر کرنل انجام می‌شود و باعث می‌شود لایه‌ها بتوانند اطلاعات بیشتری از نواحی بزرگ‌تری از تصویر را استخراج کنند. dilation به ویژه در شبکه‌های عصبی کانولوشنی برای شناسایی الگوهای بزرگ‌تر و پیچیده‌تر مفید است و معمولاً در معماری‌هایی مانند dilated Convolutions یا Atrous Convolutions مورد استفاده قرار می‌گیرد. این تکنیک به مدل اجازه می‌دهد تا بدون کاهش ابعاد تصویر، اطلاعات بیشتری را از تصاویر دریافت کند و در نتیجه دقت تشخیص را افزایش دهد.

در ادامه چهار لایه‌ی معکوس کانولوشن گیت‌دار و کانولوشن گیت‌دار برای بازسازی ابعاد تصویر نهایی قرار می‌گیرد.

این شبکه بر روی دادگان چهره‌ی CelebA-HQ [۲۴] و صحنه‌های طبیعی Places2 [۲۵] تعلیم دیده‌است. در این مقاله هدف fine-tuning کل وزن‌های لایه‌های این مدل بوده‌است تا تصاویر کنتراست XRA مخدوش شده (با ماسک عروق به‌دست آمده از فیلتر Frangi) بازسازی شوند.

برای fine-tuning این شبکه ابتدا عروق در فریم‌های حاوی ماده‌ی حاجب (تصویر کنتراست) در سکانس‌های تصاویر XRA استخراج می‌شوند. برای fine-tuning این شبکه، ورودی شامل الحاق دو تصویر است: ماسک حاصل از فیلتر Frangi و تصویر کنتراست. همچنین نزدیک‌ترین تصویر ماسک به تصویر کنتراست برای فاز تعلیم نیز نیاز است که برای تعلیم شبکه‌ی ادراکی و تمییزدهنده استفاده می‌شود.

این مدل با ترکیب شبکه‌های مولد^{۲۳}، تمییزدهنده^{۲۴} و شبکه‌ی ادراکی^{۲۵} توانایی بالایی در ایجاد تصاویری با کیفیت بالا دارد و می‌تواند در کاربرد ترمیم تصاویر مورد استفاده قرار گیرد. در ادامه به توضیح اجمالی هر یک از این شبکه‌ها پرداخته شده‌است:

شبکه‌ی مولد GrayInpaintingNet

این شبکه به‌عنوان مولد طراحی شده‌است که وظیفه‌ی ترمیم نواحی خالی در تصاویر را بر عهده دارد. ساختار این شبکه شامل لایه‌های زیر است:

چهار لایه‌ی کانولوشن گیت‌دار برای کاهش ابعاد تصویر و استخراج ویژگی‌ها استفاده می‌شود.

Gated Convolution یک نوع لایه‌ی کانولوشن است که به منظور بهبود عملکرد مدل‌های یادگیری عمیق در وظایف مختلف، به ویژه در پردازش تصویر، طراحی شده‌است. این لایه به طور خاص برای کنترل جریان اطلاعات در شبکه‌های عصبی استفاده می‌شود. در این نوع کانولوشن، از یک گیت برای تعیین اینکه چه مقدار از ویژگی‌های ورودی باید به خروجی منتقل شود، استفاده می‌شود. گیت معمولاً شامل یک لایه‌ی کانولوشن اضافی است که سیگنال ورودی را به یک مقدار بین ۰ و ۱ تبدیل می‌کند. این مقدار سپس با ویژگی‌های استخراج شده از لایه‌ی کانولوشن اصلی ترکیب می‌شود. این روند مطابق فرمول‌های زیر با ورودی I تعریف می‌شوند:

$$\text{Gating}_{y,x} = \sum \sum W_g \cdot I \quad (1)$$

$$\text{Feature}_{y,x} = \sum \sum W_f \cdot I \quad (2)$$

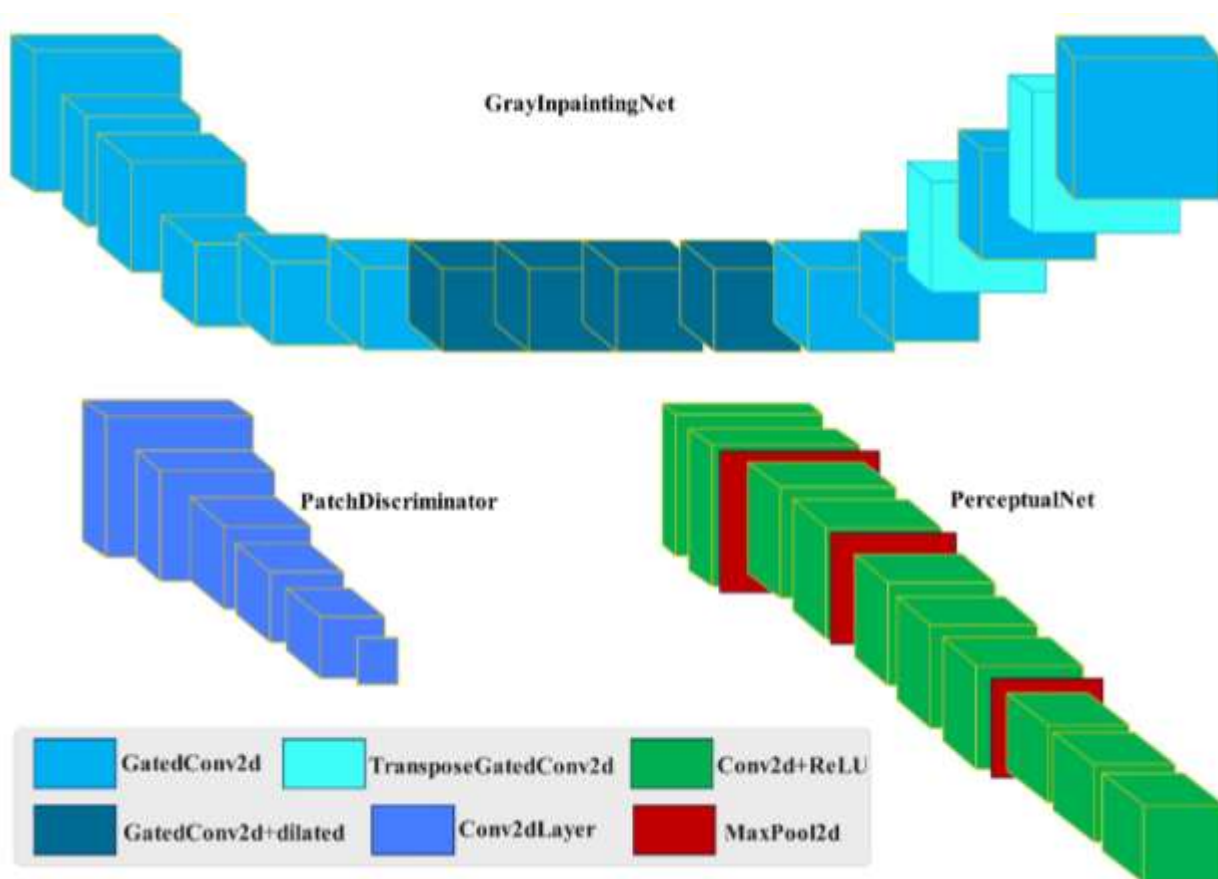
$$O_{y,x} = \phi(\text{Feature}_{y,x}) \square \sigma(\text{Gating}_{y,x}) \quad (3)$$

^{۲۵} Perceptual Network

^{۲۳} Generator

^{۲۴} Discriminator

در ورودی این شبکه ابتدا تصویر ورودی و ماسک ترکیب شده و به همدیگر الحاق می‌شوند و در خروجی ناحیه‌های خالی پر می‌شوند و تصویر ماسک شده ترمیم می‌شود.



شکل ۲. معماری سه شبکه‌ی GrayInpaintingNet، PatchDiscriminator و PerceptualNet

لایه‌ی آخر نیز یک کانال خروجی برای پیش‌بینی واقعی یا کاذب تصویر بازسازی شده است که به ابعاد 8×8 کاهش می‌یابد [۵].

شبکه‌ی ادراکی PerceptualNet

این شبکه به عنوان شبکه‌ی ادراکی عمل کرده و ویژگی‌های عمیق‌تری از تصاویر استخراج می‌کند. این شبکه از لایه‌های VGG-16 استفاده می‌کند تا ویژگی‌هایی را که برای ارزیابی کیفیت تصاویر ترمیم ضروری هستند، استخراج کند. در این شبکه، تصویر ورودی از طریق مجموعه‌ای از لایه‌ها عبور کرده و ویژگی‌های عمیق آن استخراج می‌شود. خروجی نهایی این شبکه، ویژگی‌های ادراکی تصویر است که برای محاسبه کیفیت تصاویر تولید شده استفاده خواهد شد.

ساختار این شبکه نیز شامل قسمت‌های زیر است:

این شبکه شامل چندین لایه کانولوشن، تابع فعال‌سازی ReLU و لایه‌های بیشینه ادغام است.

شبکه‌ی تمیزدهنده‌ی PatchDiscriminator

این شبکه به عنوان تمیزدهنده عمل می‌کند که وظیفه تشخیص بین تصاویر پس زمینه واقعی (نزدیک‌ترین فریم ماسک به فریم کنتراست) و تولید شده را بر عهده دارد. ورودی این شبکه تصویر تولید شده و تصویر واقعی و ماسک خروجی از فیلتر فرنگی است و خروجی این شبکه patch در ابعاد 8×8 است. این خروجی نگاشت ویژگی با ابعاد 8×8 است که نشان‌دهنده احتمال واقعی بودن تصویر در هر patch است. ساختار این شبکه شامل چندین لایه کانولوشن است که ابعاد تصویر را کاهش می‌دهند تا در نهایت یک خروجی با ابعاد کوچک‌تر تولید کنند. این شبکه دارای ساختار زیر است: ابتدا با کمک شش لایه کانولوشن است به تدریج ابعاد تصویر کاهش می‌یابد و ویژگی‌های عمیق‌تری استخراج می‌شوند.

$$\text{loss} = \lambda_{11} \times |\text{out_wholeimg-grayscale}| + \lambda_{\text{perceptual}} \times |\text{out_featuremaps-gt_featuremaps}| + (\text{۴}) \lambda_{\text{gan}} \times \text{MSE}(\text{fake_scalar}, \text{valid})$$

در فرمول بالا out_wholeimg تصویر تولید شده و تصویر grayscale تصاویر واقعی است. همچنین out_featuremaps و gt_featuremaps ویژگی‌های عمیق از تصاویر تولیدی و واقعی را نشان می‌دهد. ابتدا تصاویر به سه کانال تبدیل شده و سپس ویژگی‌های عمیق از آن‌ها استخراج می‌شود. fake_scalar و valid برای تعلیم مولد مشابه تمیزدهنده عمل می‌کند. این دو متغیر به ترتیب ویژگی‌های تصاویر جعلی و واقعی است و تعلیم شبکه‌ی مولد برای کاهش تفاوت بین این دو تلاش می‌کند. در واقع این قسمت تابع هزینه، تفاوت بین خروجی تمیزدهنده برای تصویر مولد و تصویر واقعی (برچسب valid) را محاسبه می‌کند [۵].

این ترکیب از توابع هزینه به شبکه اجازه می‌دهد تا به طور مؤثری ویژگی‌های پیچیده را یاد بگیرد و کیفیت نتایج نهایی را افزایش دهد.

پس از fine-tuning بهینه‌ی شبکه، خروجی پس‌زمینه‌ی متناظر با هر تصویر کنتراست، از تصویر کنتراست (تصویر حاوی ماده‌ی حاجب) تفریق شده تا تصویر عروق به صورت شفاف نمایش داده شود. تفریق دو تصویر (تصویر کنتراست I و پس‌زمینه‌ی بازسازی شده I₂) با کمک رابطه‌ی زیر است:

$$I_3 = \exp(\ln(I) - \ln(I_2)) \quad (۵) [۱۸]$$

۳- نتایج

۳-۱- دادگان

در این تحقیق، داده‌های بالینی شامل ۲۰ توالی XRA از ۱۵ بیمار جمع‌آوری شده است. این دادگان در مرکز تحقیقات بیمارستان قلب شهید رجایی در تهران و بوسیله‌ی دستگاه ایکس‌ری آنژیوگرافی Siemens AXIOM Artis Zee و تحت نظارت یک متخصص قلب و عروق ضبط شده‌است. توالی‌های XRA با نرخ ۱۵ فریم در ثانیه هستند و هر فریم دارای ابعاد ۵۱۲×۵۱۲ پیکسل و اندازه‌ی پیکسل ۰٫۲۷۸×۰٫۲۷۸ میلی‌متر مربع است. تعداد فریم‌ها در هر توالی معمولاً بین ۶۵ تا ۱۳۰ متغیر بوده و تمامی توالی‌ها جریان ماده‌ی حاجب را از زمان شروع تزریق تا زمانی که تقریباً ناپدید می‌شود، نمایش می‌دهند.

لایه‌ها به ترتیب تعداد کانال‌ها را افزایش می‌دهند. یعنی از ۳ کانال ورودی شروع و به ۵۱۲ کانال در لایه‌های پایانی ختم می‌شود.

دو شبکه‌ی تمیزدهنده و ادراکی اجزای کلیدی در این مدل یادگیری عمیق هستند که برای ترمیم نواحی حذف شده در تصاویر طراحی شده‌اند. تمیزدهنده با استفاده از patch‌های کوچک به شناسایی واقعی بودن تصاویر کمک می‌کند، در حالی که شبکه ادراکی ویژگی‌های عمیق‌تری را استخراج کرده و کیفیت تصاویر تولید شده را ارزیابی می‌کند. این ترکیب باعث افزایش دقت و کیفیت نتایج نهایی مدل می‌شود. معماری این سه شبکه در شکل ۲ نمایش داده شده‌است.

۲-۲-۲- fine-tuning شبکه‌ی deepfillv2-grayscale

در تعلیم این شبکه دو نوع تابع هزینه برای آموزش مدل تعریف می‌شود: L1Loss[26] و MSELoss[26]. تابع L1Loss برای محاسبه‌ی خطای بازسازی بین تصویر واقعی و تصویر تولید شده استفاده می‌شود. این تابع به شبکه کمک می‌کند تا تفاوت بین نواحی ترمیم شده و نواحی واقعی را به حداقل برساند. از سوی دیگر، MSELoss برای محاسبه خطای میانگین مربعات بین خروجی تمیزدهنده و برچسب‌های واقعی و کاذب استفاده می‌شود. این خطا به تمیزدهنده کمک می‌کند تا توانایی خود را در تشخیص تصاویر واقعی از تصاویر تولید شده بهبود بخشد [۵].

حلقه‌ی آموزش شامل ۱۰۰ دوره^{۲۶} است که در آن داده‌ها بارگذاری شده و به شبکه ارسال می‌شوند. در هر دوره، ابتدا داده‌ها (تصاویر در مقیاس خاکستری و ماسک‌ها) بر روی کارت گرافیک منتقل می‌شوند. در این مرحله، خروجی مولد با استفاده از تصاویر ورودی و ماسک محاسبه می‌شود و تمیزدهنده با استفاده از خروجی مولد و تصاویر واقعی آموزش داده می‌شود تا توانایی تشخیص واقعی بودن تصاویر را افزایش دهد. پس از آن، شبکه مولد مجدداً با استفاده از تصاویر ورودی و ماسک آموزش داده می‌شود.

در مرحله‌ی آموزش مولد، خطاهای L1، ادراکی و GAN محاسبه شده و وزن‌های مدل با استفاده از روش پس‌انتشار^{۲۷} به‌روز می‌شوند. این فرآیند شامل محاسبه‌ی خطاهای L1 برای ارزیابی کیفیت ترمیم نواحی حذف شده، محاسبه‌ی خطای ادراکی برای ارزیابی ویژگی‌های عمیق تصویر و محاسبه‌ی خطای GAN برای ارزیابی واقعی بودن تصاویر تولید شده است. تابع هزینه کلی برای آموزش شبکه مطابق رابطه‌ی زیر است:

^{۲۷} backpropagation

^{۲۶} epoch

$$SSIM = \frac{(2\mu_v\mu_f + C_1)(2\sigma_{vf} + C_2)}{(\mu_v^2 + \mu_f^2 + C_1) + (\sigma_v^2 + \sigma_f^2 + C_2)} \quad (9)$$

$C_1=0.01$ و $C_2=0.03$ پارامترهای ثابت هستند [۲۷]. μ_f و μ_v میانگین شدت روشنایی پیکسل‌های عروق حاوی ماده‌ی حاجب در فریم کنتراست و پیکسل‌های عروق استخراج شده از الگوریتم پیشنهادی و روش‌های سنتی را نشان می‌دهند. همچنین، σ_v و σ_f واریانس شدت روشنایی پیکسل‌های عروق حاوی ماده‌ی حاجب در فریم کنتراست و پیکسل‌های عروق استخراج شده از الگوریتم پیشنهادی و روش‌های سنتی را بیان می‌کنند. σ_{vf} هم کوواریانس شدت روشنایی پیکسل‌های رگ در بین فریم کنتراست و عروق خروجی از شبکه‌ی $deepfillv2$ -grayscale و روش‌های سنتی است.

این چهار معیار با محاسبه‌ی میانگین و واریانس روی ۱۵ نمونه برای خروجی $deepfillv2$ -grayscale و روش‌های سنتی حذف پس‌زمینه‌ی ذکر شده نسبت به عروق استخراجی از فریم کنتراست، مطابق جدول ۱ به‌دست آمده‌است. نمودار میله‌ای با هدف مقایسه نیز در شکل ۳ نمایش داده شده‌است.

روش‌های سنتی حذف پس‌زمینه استفاده شده دارای مزیت‌ها و معایب معینی هستند. روش OTS-RPCA شامل چند مرحله است. ابتدا، یک عملیات بسته شدن مورفولوژیکی به عنوان مرحله پیش‌پردازش برای حذف ساختارهای بزرگ مقیاس مانند ستون فقرات، قفسه سینه و دیافراگم استفاده می‌شود. سپس، توالی XRA به سه زیرفضا تقسیم می‌شود: پس‌زمینه‌ی کم‌رتبه، پس‌زمینه‌ی دینامیک باقی‌مانده و پیش‌زمینه‌ی عروقی. در این روش یک نرم ^{۳۱} ساختار درختی معرفی می‌شود که بر روی زیرماتریس عروقی اعمال می‌شود تا همخوانی فضایی عروق را تضمین کند. همچنین، پس‌زمینه‌ی دینامیک باقی‌مانده به طور جداگانه استخراج می‌شود تا نویز و آثار حرکتی از پیش‌زمینه‌ی عروق حذف شود. این الگوریتم از یک ضریب تنظیم تطبیقی استفاده می‌کند که تغییرات ناحیه عروقی را در فریم‌های XRA ردیابی می‌کند. مدت زمان پردازش این الگوریتم بسیار طولانی است. به‌طور مثال برای نمایش خروجی یک فیلم حاوی ۷۰ فریم، مدت زمان پردازش ۲۵ دقیقه‌ای نیاز است.

برای تحلیل داده‌ها، مجموعه داده به دو بخش تقسیم شده است: ۸۵٪ از داده‌ها برای fine-tuning شبکه‌ی $deepfillv2$ -grayscale و ۱۵٪ باقی‌مانده برای ارزیابی کیفیت استخراج عروق و پس‌زمینه‌های بازسازی شده استفاده می‌شود. آزمایشات در محیط نرم‌افزار Spyder و با استفاده از فریم‌ورک Pytorch انجام شده‌است. سیستم کامپیوتری مورد استفاده دارای پردازنده Intel Core i7-4790K، حافظه RAM معادل ۳۲ گیگابایت و کارت گرافیک NVIDIA GeForce GTX TitanX است.

۲-۳- معیارهای ارزیابی

برای مقایسه‌ی پیش‌زمینه‌های به‌دست آمده از روش پیشنهادی این مقاله و روش‌های سنتی [27] OTS-RPCA، PCP- [28] RPCA^{۲۸}، [29] FPCP-RPCA^{۲۹}، [30] MAMR، [31] OSTD و [32] DECOLOR^{۳۰} از معیارهای ارزیابی Precision [33]، Recall [33]، F1-Score [33] و SSIM [34] استفاده شده‌است. Precision نشان‌دهنده‌ی دقت شناسایی عروق توسط مدل است، به این معنی که چه تعداد از پیکسل‌های شناسایی شده به‌عنوان عروق، واقعاً جزو عروق بوده‌اند. Recall نیز میزان شناسایی کامل عروق واقعی را ارزیابی می‌کند که فرمول‌های این دو معیار به شکل زیر تعریف می‌شوند:

$$Precision = \frac{tp}{tp+fp} \quad (6)$$

$$Recall = \frac{tp}{tp+fn} \quad (7)$$

که tp پیکسل‌های جزو عروق را که به درستی شناسایی شده‌اند نشان می‌دهد. fp پیکسل‌هایی است که به اشتباه جزو عروق شناسایی شده‌اند و fn پیکسل‌هایی هستند که جزو عروق بوده‌اند اما مدل نتوانسته آن‌ها را شناسایی کند. برای ارزیابی بهتر عملکرد مدل، امتیاز F1 که میانگین Precision و Recall است، محاسبه می‌شود تا تعادلی میان دقت و توانایی مدل در شناسایی صحیح پیکسل‌ها ایجاد کند. فرمول این معیار مطابق فرمول زیر تعریف می‌شود:

$$F1 = \frac{2 Precision Recall}{Precision + Recall} \quad (8)$$

در روش حذف پس‌زمینه باید ساختار رگ‌ها حفظ شود. بنابراین، چهارمین معیار برای ارزیابی مدل پیشنهادی SSIM [34] است که بر اساس ارزیابی کیفیت رگ‌های استخراج شده مورد استفاده قرار گرفته است.

فرمول SSIM مطابق زیر تعریف می‌شود:

^{۳۱} Norm

²⁸ <https://github.com/dlaptv/RobustPCA>

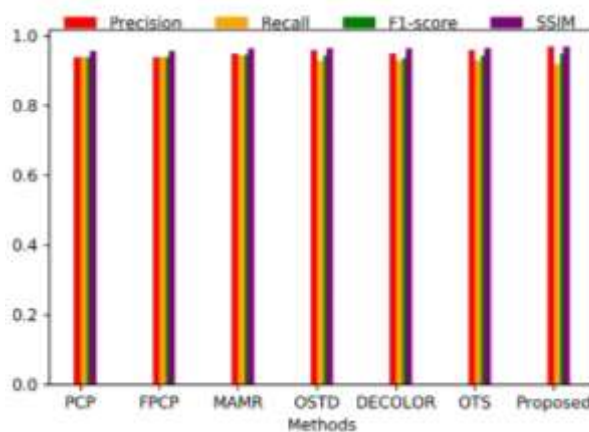
²⁹ <https://github.com/andrewssobral/rlslibrary>

³⁰ <https://bioinformatics.hkust.edu.hk/decOLOR/decOLOR.html>

روش‌ها پیچیدگی محاسباتی کمتری دارند و قادرند سرعت پردازش را افزایش دهند.

با این حال، هنگامی که با داده‌های با ابعاد بالا یا صحنه‌های پیچیده مواجه می‌شوند، ممکن است دقت آن‌ها کاهش یابد. به همین دلیل، برای محیط‌های با پیچیدگی بالا و داده‌های زیاد، این روش‌ها به‌طور کامل کارآمد نیستند و ممکن است به کاهش کیفیت نتایج منجر شوند.

در نهایت، روش‌های دیگری مانند OSTD^{۳۴} و DECOLOR نیز برای مدیریت پس‌زمینه‌های دینامیک و بهبود کیفیت تصویر کاربرد دارند. DECOLOR به‌ویژه در مدیریت پس‌زمینه‌های متغیر بسیار مؤثر است، اما به دلیل زمان اجرای طولانی‌تری که نسبت به سایر روش‌ها دارد محدودیت‌هایی را به وجود می‌آورد. روش پیشنهادی در این مطالعه با کاهش پیچیدگی محاسباتی و پردازش همزمان تنها دو فریم از توالی تصاویر، امکان انجام پردازش سریع‌تر را فراهم کرده است و دقت بالاتری در جداسازی پس‌زمینه از پیش‌زمینه در تصاویر آنژیوگرافی مطابق جدول ۱، ارائه می‌دهد. این ویژگی‌ها باعث می‌شود که این روش به‌ویژه برای کاربردهای پزشکی که نیاز به زمان پردازش کوتاه و دقت بالا دارند، گزینه‌ای مناسب و مؤثر باشد. مقایسه‌ی خروجی این روش‌های به‌صورت کیفی در شکل ۴ نمایش داده شده‌است.



شکل ۳. میانگین و انحراف معیار $F1$ -score recall precision و شاخص $SSIM$ به‌دست‌آمده از طریق روش‌های سنتی و روش پیشنهادی.

همچنین در مقایسه روش‌های مختلف پردازش تصویر برای جداسازی پس‌زمینه و پیش‌زمینه در تصاویر XRA، روش PCP-^{۳۲} RPCA یکی از پرکاربردترین‌هاست. این روش توانایی مقابله با نویز و تغییرات روشنایی در محیط‌های دینامیک را دارد، اما پیچیدگی محاسباتی بالای آن باعث می‌شود که در زمان‌بندی‌های واقعی با چالش‌هایی مواجه شود.

به این ترتیب، پیاده‌سازی این روش در سیستم‌های زمان واقعی ممکن است به‌کندی عملکرد منجر شود و برای کاربردهای سریع‌تر مناسب نباشد.

در این راستا، روش‌های دیگری مانند FPCP-RPCA و MAMR^{۳۳} بهبودهایی در عملکرد محاسباتی ارائه می‌دهند. این

method	PCP-RPCA	FPCP-RPCA	MAMR	OSTD	DECOLOR	OTS-RPCA	Proposed algorithm
Precision	0.94±0.029	0.94±0.009	0.95±0.009	0.96±0.005	0.95±0.0046	0.96±0.0025	0.97±0.062
Recall	0.94±0.0032	0.94±0.008	0.944±0.003	0.93±0.009	0.93±0.0012	0.93±0.001	0.92±0.0043
F1-score	0.94±0.0052	0.94±0.008	0.947±0.008	0.944±0.007	0.936±0.0029	0.945±0.006	0.95±0.007
SSIM	0.958±0.001	0.958±0.007	0.965±0.0057	0.966±0.002	0.965±0.0029	0.966±0.0092	0.97±0.0081

جدول ۱: مقایسه کمی برخی از روش‌های شناخته‌شده با روش پیشنهادی

ایده‌آل‌ترین حالت خروجی این فیلتر لحاظ شده است تا صرفاً کیفیت بازسازی پس‌زمینه ملاک مقایسه‌ی خروجی روند پیشنهادی این مقاله و سایر روش‌های سنتی باشد. در واقع تمرکز بر روی بازسازی پس‌زمینه و بهبود نمایش فریم کنتراست است. بنابراین همان‌طور که ذکر شد بهبودهایی روی ماسک خروجی از این فیلتر اعمال شد تا عروق به‌صورت خالص استفاده شود تا بتوان کیفیت خروجی شبکه‌ی ترمیم

فیلتر Frangi به‌طور خاص برای تشخیص عروق طراحی شده و در تشخیص ساختارهای عروقی ساده عملکرد مناسبی دارد. این فیلتر معمولاً دقت مناسبی در تشخیص عروق با وضوح بالا دارد، اما در شرایط پیچیده‌تر یا تصاویر با نویز بالا ممکن است نتایج دقیقی ارائه ندهد.

در این شرایط، ممکن است پیکسل‌هایی به‌طور اشتباه به‌عنوان عروق تشخیص داده شوند. در این مقاله با بهبود این فیلتر

³⁴ Online Spatio-Temporal Decomposition

^{۳۲} Principal Component Pursuit-Robust Principal Component Analysis

³³ Matrix Approximation via Matrix Reconstruction

می‌توانند جزئیات حیاتی رگ‌ها را پنهان کنند و باعث ایجاد نمایشی ناقص یا نادرست از رگ‌ها شوند. آرتیفکت‌ها، مانند سایه‌ها یا سایر اختلالات در فرآیند تصویربرداری، می‌توانند نشانه‌های بصری گمراه‌کننده‌ای ایجاد کنند که تفسیر داده‌های عروقی را پیچیده‌تر می‌کنند. اگرچه روش پیشنهادی کیفیت قابل قبولی در بازسازی پس‌زمینه نشان داده است، اما در برخی موارد این چالش‌ها در خروجی‌های آن مشاهده می‌شود.


همچنین در این تحقیق، به دلیل عدم وجود مقالات معتبر و قابل استناد که به‌طور خاص از روش‌های یادگیری عمیق برای حذف پس‌زمینه‌ی تصاویر XRA در عروق کرونری استفاده کرده باشند، مقایسه‌ی نتایج تنها با روش‌های سنتی موجود در این حوزه انجام شد. این روش‌ها که به‌طور گسترده در کارهای مشابه به‌کار رفته‌اند، برای ارزیابی کارایی و دقت روش پیشنهادی انتخاب شدند.

deepfillv2-grayscale را با سایر روش‌های سنتی از جهت کیفیت سنجید.

پس از اعمال ماسک‌های بدست آمده، فریم کنتراست و ماسک به عنوان ورودی به شبکه‌ی deepfillv2-grayscale داده می‌شود تا شبکه‌ی fine-tuning شده و خروجی‌های پس‌زمینه‌ی بازسازی شده به‌دست آید. پس‌زمینه‌های بازسازی شده از شبکه‌ی deepfillv2-grayscale در شکل ۵ نمایش داده شده‌است.

۴- بحث

در شکل ۵، برخی از خروجی‌های روش پیشنهادی نمایش داده شده‌است. چالش‌هایی وجود دارند که ممکن است منجر به استخراج ساختارهای عروقی آسیب‌دیده به دلیل نویز و آرتیفکت‌ها^{۳۵} در مرحله نهایی روش پیشنهادی شوند. نویزها



شکل ۴. نتایج تفریق پس‌زمینه با کمک مدل پیشنهادی، (a_1) ، $OTS-RPCA(a_2)$ ، $PCP-RPCA(a_3)$ ، $FPCP-RPCA(a_4)$ ، $MAMR(a_5)$ ، $OSTD(a_6)$ ، $DECOLOR(a_7)$

شایان ذکر است که بعد از مرحله اعمال فیلتر Frangi، هنگام ایجاد ماسک رگ، ممکن است برخی نواحی غیرعروقی به‌طور اشتباه شناسایی شده و کدهای ویژگی آن‌ها از کدهای ماسک فریم جایگزین شوند. این جایگزینی‌های اشتباهی در برخی نواحی کوچک، گاهی اوقات نویزهای جزئی ایجاد می‌کنند که در خروجی‌های روش مشاهده می‌شود. اما این مشکل حیاتی نیست، زیرا هدف نهایی این کار افزایش وضوح بخش‌هایی از

در تحقیقات آینده، قصد داریم مدل پیشنهادی را با اصلاحات مناسب تقویت کنیم. این مهم می‌تواند شامل پیاده‌سازی الگوریتم‌های پیشرفته حذف نویز و بهبود تکنیک‌های شناسایی و حذف سایه‌ها باشد. همانطور که در شکل ۵ مشاهده می‌شود، با اعمال فرآیند تفاضل، رگ‌هایی که حاوی ماده‌ی کنتراست هستند به وضوح نمایش داده شده و پس‌زمینه‌ها به‌طور چشمگیری حذف شده‌اند.


^{۳۵} Artifacts

ناشی از بافت‌های مختلف بدن و همچنین حرکت‌های غیرقابل پیش‌بینی است. تحقیق حاضر به هدف رفع این چالش‌ها از شبکه‌های عصبی عمیق استفاده کرده است. در این روش، پس‌زمینه هر فریم کنتراست انتخاب شده بازسازی می‌شود و سپس سایه‌های ناخواسته با استفاده از یک تکنیک تفاضلی معتبر، حذف می‌شوند. هدف اصلی این تحقیق، بازسازی دقیق پس‌زمینه فریم‌های تصویربرداری رگ‌ها است. ابتدا سایه‌های رگ‌ها حذف شده و سپس نواحی حذف‌شده با استفاده از اطلاعات فریم ماسک و فریم کنتراست ماسک شده با خروجی فیلتر فرنگی ترمیم می‌شود.

تصویر است که رگ‌های اصلی قلب در آن‌ها قرار دارند، به‌طوری که پزشک بتواند تشخیص‌های لازم را بهتر انجام دهد. در صورتی که تغییرات ناخواسته‌ای در نواحی غیرعروقی ایجاد شود، پزشک آن‌ها را متوجه نخواهد شد و این مسئله تأثیری در تشخیص نهایی نخواهد داشت.

۵- نتیجه‌گیری

در فرآیندهای تصویربرداری XRA، پزشکان اغلب با چالش‌هایی مواجه هستند که ناشی از سایه‌های ناخواسته و تغییرات نور



شکل ۵. ردیف اول: تصویر کنتراست - ردیف دوم: پس‌زمینه‌ی بازسازی شده متناظر با تصویر کنتراست - ردیف سوم: حذف ۶۰٪ پس‌زمینه برای نمایش عروق حاوی ماده‌ی حاجب.

آنژیوگرافی با دقت و کیفیت بالاتری انجام شود. همچنین، توصیه می‌شود تکنیک‌های پیشرفته‌ی پردازش پس از بازسازی پس‌زمینه مانند حذف نویز، به‌طور جدی مورد توجه قرار گیرند. بهینه‌سازی الگوریتم بازسازی و افزایش سرعت پردازش و همچنین بررسی ادغام آن با سیستم‌های تصویربرداری در زمان واقعی به منظور بهبود جریان کار بالینی می‌تواند بسیار مفید باشد. اولویت‌بندی این تحقیقات آینده می‌تواند دقت استخراج رگ‌ها را افزایش دهد و به بهبود توانایی‌های تشخیصی و نتایج بهتر در محیط‌های بالینی منجر شود.

منابع

نتایج نشان داده‌اند که این تکنیک در بازسازی دقیق پس‌زمینه‌ها در توالی‌های XRA که حاوی ماده‌ی حاجب هستند، مؤثر بوده‌است و نسبت به برخی از روش‌های پیشرفته‌ی دیگر مزیت‌های زیادی دارد که قبلاً ذکر شد. برای توسعه و بهبود روش پیشنهادی، برخی از زمینه‌های کلیدی باید در نظر گرفته شوند. اولین اولویت باید به بهبود استخراج رگ‌ها برای تولید ماسک با استفاده از یادگیری عمیق اختصاص یابد. استفاده از روش‌های یادگیری عمیق می‌تواند بین ساختارهای واقعی رگ و آرتیفکت‌های اضافی تمایز بهتری ایجاد کند. علاوه بر این، مدل عمیقی که در این مقاله پیشنهاد شده، باید با طراحی و بهبود یابد تا بازسازی پس‌زمینه تصاویر



- conference on computer vision and pattern recognition, 2018, pp. 5505-5514.
- [۱۴] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin, and A. C. Courville, "Improved training of wasserstein gans," *Advances in neural information processing systems*, vol. 30, 2017.
- [۱۵] J. Adler and S. Lunz, "Banach wasserstein gan," *Advances in neural information processing systems*, vol. 31, 2018.
- [۱۶] Z. Yi, Q. Tang, S. Azizi, D. Jang, and Z. Xu, "Contextual residual aggregation for ultra high-resolution image inpainting," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 7508-7517.
- [۱۷] S. Qu, Z. Niu, J. Zhu, B. Dong, and K. Huang, "Structure first detail next: Image inpainting with pyramid generator," in *2023 IEEE International Conference on Multimedia and Expo (ICME)*, 2023: IEEE, pp. 1265-1270.
- [۱۸] S. Song *et al.*, "Patch-based adaptive background subtraction for vascular enhancement in X-ray cineangiograms," *IEEE journal of biomedical and health informatics*, vol. 23, no. 6, pp. 2563-2575, 2019.
- [۱۹] M. Voorn, U. Exner, and A. Rath, "Multiscale Hessian fracture filtering for the enhancement and segmentation of narrow fractures in 3D image data," *Computers & geosciences*, vol. 57, pp. ۲۰۱۳-۵۳-۴۴
- [۲۰] S. Tang, Y. Wang, and Y.-W. Chen, "Application of ICA to X-ray coronary digital subtraction angiography," *Neurocomputing*, vol. 79, pp. 168-172, 2012.
- [۲۱] Y. Bentoutou and N. Taleb, "Automatic extraction of control points for digital subtraction angiography image enhancement," *IEEE Transactions on Nuclear Science*, vol. 52, no. 1, pp. 238-246, 2005.
- [۲۲] M. Nejati, S. Sadri, and R. Amirfattahi, "Nonrigid Image Registration in Digital Subtraction Angiography Using Multilevel B-Spline," *BioMed research international*, vol. 2013, no. 1, p. 236315, 2013.
- [۲۳] H. Ma, A. Hoogendoorn, E. Regar, W. J. Niessen, and T. van Walsum, "Automatic online layer separation for vessel enhancement in X-ray angiograms for percutaneous coronary interventions," *Medical image analysis*, vol. 39, pp. 145-161, 2017.
- [۲۴] Z. Liu, P. Luo, X. Wang, and X. Tang, "Large-scale celebfaces attributes (celeba) dataset," *Retrieved August*, vol. 15, no. 2018, p. 11, 2018.
- [۲۵] B. Zhou, A. Khosla, A. Lapedriza, A. Torralba, and A. Oliva, "Places: An image database for deep scene understanding," *arXiv preprint arXiv:1610.02055*, 2016.
- [۲۶] H. Zhao, O. Gallo, I. Frosio, and J. Kautz, "Loss functions for image restoration with neural networks," *IEEE Transactions on computational imaging*, vol. 3, no. 1, pp. 47-57, 2016.
- [۲۷] S. Shakeri and F. Almasganj, "Online tree-structure-constrained RPCA for background subtraction of X-ray coronary angiography images," *Computer Methods and Programs in Biomedicine*, vol. 258, p. 108463, 2025.
- [۲۸] H. Ma *et al.*, "Layer separation for vessel enhancement in interventional X-ray angiograms
- [۱] Z. Gao *et al.*, "Vessel segmentation for X-ray coronary angiography using ensemble methods with deep learning and filter-based features," *BMC Medical Imaging*, vol. 22, no. 1, p. 10, 2022.
- [۲] P. Gailloud, S. Oishi, and K. Murphy, "Three-dimensional fusion digital subtraction angiography: new reconstruction algorithm for simultaneous three-dimensional rendering of osseous and vascular information obtained during rotational angiography," *American journal of neuroradiology*, vol. 26, no. 4, pp. 908-911, 20۰۵
- [۳] W. Quan, J. Chen, Y. Liu, D.-M. Yan, and P. Wonka, "Deep learning-based image and video inpainting: A survey," *International Journal of Computer Vision*, vol. 132, no. 7, pp. 2367-2400, 2024.
- [۴] A. F. Frangi, W. J. Niessen, K. L. Vincken, and M. A. Viergever, "Multiscale vessel enhancement filtering," in *Medical Image Computing and Computer-Assisted Intervention—MICCAI'98: First International Conference Cambridge, MA, USA, October 11–13, 1998 Proceedings 1*, 1998: Springer, pp. 130-137.
- [۵] J. Yu, Z. Lin, J. Yang, X. Shen, X. Lu, and T. S. Huang, "Free-form image inpainting with gated convolution," in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 4471-4480.
- [۶] K. B. Khan, A. A. Khaliq, A. Jalil, and M. Shahid, "A robust technique based on VLM and Frangi filter for retinal vessel extraction and denoising," *PloS one*, vol. 13, no. 2, p. e0192203, 2018.
- [۷] D. Jimenez-Carretero, A. Santos, S. Kerkstra, R. D. Rudyanto, and M. J. Ledesma-Carbayo, "3D Frangi-based lung vessel enhancement filter penalizing airways," in *2013 IEEE 10th international symposium on biomedical imaging*, 2013: IEEE, pp. 926-929.
- [۸] C. Barnes, E. Shechtman, A. Finkelstein, and D. B. Goldman, "PatchMatch: A randomized correspondence algorithm for structural image editing," *ACM Trans. Graph.*, vol. 28, no. 3, p. 24, 2009.
- [۹] S. Darabi, E. Shechtman, C. Barnes, D. B. Goldman, and P. Sen, "Image melding: Combining inconsistent images using patch-based synthesis," *ACM Transactions on graphics (TOG)*, vol. 31, no. 4, pp. 1-10, 2012.
- [۱۰] D. Pathak, P. Krahenbuhl, J. Donahue, T. Darrell, and A. A. Efros, "Context encoders: Feature learning by inpainting," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 25۰۵۴۴-۳۶
- [۱۱] S. Iizuka, E. Simo-Serra, and H. Ishikawa, "Globally and locally consistent image completion," *ACM Transactions on Graphics (ToG)*, vol. 36, no. 4, pp. 1-14, 2017.
- [۱۲] G. Liu, F. A. Reda, K. J. Shih, T.-C. Wang, A. Tao, and B. Catanzaro, "Image inpainting for irregular holes using partial convolutions," in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 85-100.
- [۱۳] J. Yu, Z. Lin, J. Yang, X. Shen, X. Lu, and T. S. Huang, "Generative image inpainting with contextual attention," in *Proceedings of the IEEE*



- using morphological filtering and robust PCA," in *Augmented Environments for Computer-Assisted Interventions: 10th International Workshop, AE-CAI 2015, Held in Conjunction with MICCAI 2015, Munich, Germany, October 9, 2015. Proceedings 10*, 2015: Springer, pp. 104-113.
- [۲۹] R. Chen, Y. Tong, J. Yang, and M. Wu, "Video foreground detection algorithm based on fast principal component pursuit and motion saliency," *Computational intelligence and neuroscience*, vol. 2019, no. 1, p. 4769185, 2019.
- [۳۰] X. Ye, J. Yang, X. Sun, K. Li, C. Hou, and Y. Wang, "Foreground-background separation from video clips via motion-assisted matrix restoration," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 25, no. 11, pp. 1721-1734, 2015.
- [۳۱] A. Sobral, S. Javed, S. Ki Jung, T. Bouwmans, and E.-h. Zahzah, "Online stochastic tensor decomposition for background subtraction in multispectral video sequences," in *Proceedings of the IEEE International Conference on Computer Vision Workshops*, 2015, pp. 106-113.
- [۳۲] X. Zhou, C. Yang, and W. Yu, "Moving object detection by detecting contiguous outliers in the low-rank representation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 3, pp. 597-610, 2012.
- [۳۳] D. M. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," *arXiv preprint arXiv:2010.16061*, 2020.
- [۳۴] Z. Wang, E. P. Simoncelli, and A. C. Bovik, "Multiscale structural similarity for image quality assessment," in *The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, 2003*, 2003, vol. 2: Ieee, pp. 1398-1402.