

## مروری بر روش‌های بخش‌بندی پلاک‌های ام‌اس در تصاویر ام‌آرآی با استفاده از انواع شبکه‌های U-Net

فریبا نمیرانیان<sup>۱</sup>، علی محمد لطیف<sup>۲\*</sup>، مهدی یزدیان دهکردی<sup>۳</sup>، ابوالفضل نیک فرجام<sup>۴</sup>

<sup>۱</sup> دانشجوی دکتری، دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران

<sup>۲</sup> استاد، دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران

<sup>۳</sup> دانشیار، دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران

<sup>۴</sup> دانشیار دانشگاه علوم پزشکی شهید صدوقی یزد، یزد، ایران

### مقاله پژوهشی

### چکیده

#### تاریخ دریافت:

۱۴۰۴/۲/۱۷

#### تاریخ پذیرش:

۱۴۰۴/۴/۱

#### کلیدواژه‌ها:

بخش‌بندی تصویر، بیماری

ام‌اس، تشخیص پلاک مغزی،

ماژول توجه، یادگیری عمیق

#### نویسنده مسئول:

alatif@yazd.ac.ir

بیماری ام‌اس یکی از شایع‌ترین اختلال‌های خودایمنی سیستم عصبی مرکزی است. این بیماری با تخریب غلاف میلین سلول‌های عصبی و ایجاد پلاک‌هایی در بافت مغز و نخاع همراه است. تشخیص دقیق پلاک‌ها در تصاویر ام‌آرآی نقش کلیدی در شناسایی بیماری، پیش‌بینی وضعیت بهبودی بیمار و انتخاب روش درمانی مناسب دارد. در این مقاله با رویکردی مروری و تحلیلی، عملکرد سه معماری پرکاربرد یادگیری عمیق شامل U-Net، ResUNet و AttentionUNet در بخش‌بندی پلاک‌های ام‌اس بررسی و مقایسه شده است. پس از معرفی مجموعه دادگان و معیارهای ارزیابی متداول در این حوزه، نتایج ۳۴ مقاله معتبر با استفاده از معیار Dice تحلیل گردید. معماری‌های U-Net، ResUNet و AttentionUNet به‌طور میانگین به ترتیب امتیاز Dice برابر با ۰/۶۵۶۲، ۰/۶۹۳۷ و ۰/۷۴۳۵ را در بخش‌بندی پلاک‌های ام‌اس در پژوهش‌های مرور شده کسب کرده‌اند. نتایج نشان می‌دهد AttentionUNet عملکرد مناسب‌تری نسبت به سایر روش‌ها دارد. هم‌چنین نقاط قوت و ضعف هر روش تحلیل و مسیرهای آینده پژوهشی در این زمینه پیشنهاد شده است.

doi : 10.22034/ABMIR.2025.23082.1126

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2025.23082.1126)

/The Author 2025. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).



## ۱- مقدمه


افزایش است. هرچند علت دقیق این بیماری هنوز به طور کامل مشخص نشده؛ اما عوامل محیطی و اثرات ژنتیکی از محتمل‌ترین دلایل آن به شمار می‌روند [۲].

تصویربرداری تشدید مغناطیسی<sup>۳</sup> که با نام ام‌آرآی شناخته می‌شود یکی از مهم‌ترین روش‌های تصویربرداری پزشکی است. ام‌آرآی یک تکنیک تصویربرداری غیرتهاجمی مناسب برای بررسی مغز است. ام‌آرآی از حساسیت بالایی برای تشخیص پلاک‌های ام‌اس برخوردار بوده و می‌تواند ارزیابی کمی از فعالیت التهابی و حجم ضایعه‌ها ارائه دهد. این ویژگی ام‌آرآی را به ابزار کلیدی برای تشخیص بیماری ام‌اس و همچنین بررسی اثربخشی درمان‌های دارویی تبدیل کرده است.

وجود پلاک‌ها و ظاهر شدن ضایعه‌های جدید در تصاویر ام‌آرآی از اجزای کلیدی معیارهای تشخیص فعلی این بیماری هستند. بخش‌بندی پلاک‌های ام‌اس، گام نخست و ضروری برای توصیف بیماری و محاسبه و تفسیر دقیق‌تر شاخص‌های آسیب‌شناسی است. در شکل ۲ نمونه‌ای از تصویر ام‌آرآی فرد سالم و بیمار آورده شده است. در تصویر سمت چپ پلاک‌های مغزی در فرد بیمار به صورت نواحی خاکستری کم‌رنگ مشاهده می‌شود. ام‌آرآی به پزشک کمک می‌کند تا بر نحوه رشد پلاک‌های بیماری و اثربخشی درمان نظارت کنند [۴].



(ب) فرد بیمار



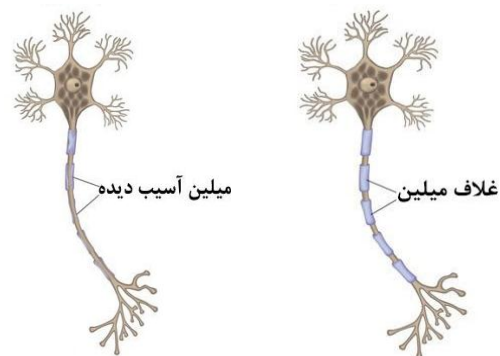
(الف) فرد سالم

شکل (۲): یک نمونه تصویر ام‌آرآی مغزی [۵]

تشخیص پلاک‌های مغزی به صورت دیداری و توسط نورورادیولوژیست‌ها انجام می‌شود؛ اما بخش‌بندی دستی

بیماری ام‌اس<sup>۱</sup> بیماری مزمن است که با علائم بالینی مختلف، دستگاه عصبی مرکزی را درگیر می‌کند. ام‌اس بیماری عصبی پیش‌رونده است که موجب تغییر در ساختار مغز می‌شود و به‌طور معمول ناتوانی‌هایی را در افراد جوان ایجاد می‌کند. این بیماری باعث نابودی پوشش‌های میلینی در نورون‌های عصبی مغز و نخاع می‌شود.

پوشش میلین<sup>۲</sup> یک لایه پروتئینی روی رشته‌های عصبی است. در شکل ۱ پوشش میلین در فرد سالم و فرد مبتلا به ام‌اس نشان داده شده است. پوشش میلین با افزایش سرعت هدایت پیام‌های الکتریکی در طول تار عصبی، نقش مهمی در عملکرد مؤثر سیستم عصبی و حفظ سلامت نورون‌ها دارد. زمانی که پوشش میلینی از بین می‌رود پیام صادره از مغز در طول عصب متوقف می‌شود و یا به کندی انتقال می‌یابد. بسته به ناحیه‌ای از سیستم عصبی که درگیر شده است، علائمی از جمله تاری دید، ضعف شدید و تحلیل عضلانی تا اختلال در هماهنگی و عملکرد شناختی بروز می‌کنند [۱].



(ب) فرد بیمار

(الف) فرد سالم

شکل (۱): پوشش میلین آسیب‌دیده در عصب [۳]

شیوع بیماری ام‌اس در زنان بیش‌تر از مردان است و نرخ ابتلا پس از سن ۱۸ سالگی به سرعت افزایش یافته و در بازه ۲۵ تا ۳۵ سال به اوج می‌رسد و سپس به تدریج کاهش می‌یابد. این بیماری در سنین بالای ۵۰ سال نادر می‌شود. براساس جدیدترین مطالعه‌های سازمان جهانی بهداشت شیوع این بیماری در سراسر جهان در حال

<sup>۲</sup> Myelin

<sup>۳</sup> Magnetic Resonance Imaging (MRI)

<sup>۱</sup> Multiple Sclerosis (MS)



جمع‌بندی نتایج و پیشنهادهایی برای پژوهش‌های آینده ارائه خواهد شد.

## ۲- مواد و روش‌ها

این مطالعه با هدف ارائه یک مرور هدف‌مند و ساختاریافته از پژوهش‌های انجام‌شده در زمینه بخش‌بندی پلاک‌های بیماری ام‌اس در تصاویر ام‌آرآی، با تکیه بر معماری‌های یادگیری عمیق و با بهره‌گیری از اصول مرور نظام‌مند ادبیات<sup>۱</sup> انجام شده است. مراحل انجام این فرآیند به شرح زیر است:

۱- **تعریف هدف و پرسش پژوهش:** هدف اصلی این پژوهش بررسی عملکرد معماری‌های یادگیری عمیق پرکاربرد شامل U-Net، ResUNet و AttentionUNet در بخش‌بندی خودکار پلاک‌های بیماری ام‌اس در تصاویر ام‌آرآی است. بر این اساس، پرسش اصلی پژوهش چنین تعریف شد: کدام‌یک از این معماری‌ها در این حوزه عملکرد دقیق‌تری داشته‌اند و چه نقاط قوت و ضعفی برای هر یک گزارش شده است؟

۲- **جست‌وجوی منابع علمی:** برای گردآوری منابع علمی مرتبط، جست‌وجویی جامع در پایگاه‌های اطلاعاتی معتبر شامل Google Scholar، Web of Science، ScienceDirect، PubMed و Elsevier انجام شد. کلیدواژه‌های مورداستفاده در جست‌وجو شامل عبارت‌هایی هم‌چون بخش‌بندی خودکار پلاک‌های ام‌اس در تصاویر ام‌آرآی، معماری‌های یادگیری عمیق در بخش‌بندی تصاویر ام‌آرآی، کاربرد U-Net در بخش‌بندی پلاک‌های ام‌اس، مقایسه رویکردهای یادگیری عمیق در تشخیص پلاک‌های ام‌اس، AttentionUNet در بخش‌بندی تصاویر ام‌آرآی، ResUNet در بخش‌بندی پلاک‌های ام‌اس و یادگیری عمیق در بخش‌بندی تصاویر پزشکی بودند.

۳- **معیارهای انتخاب و غربال‌گری:** در گام اول مقاله‌های بررسی شده بر اساس معیارهایی مانند در دسترس بودن متن کامل مقاله، استفاده از تصاویر ام‌آرآی، ارائه معیارهای ارزیابی کمی مانند Dice، بهره‌گیری از معماری‌های یادگیری عمیق و

پلاک‌های ام‌اس فرآیندی زمان‌بر، دشوار و مستعد خطای انسانی است. همین مسئله باعث شده که توسعه روش‌های خودکار برای بخش‌بندی پلاک‌های ام‌اس به یک نیاز اساسی و کمک مؤثر برای نورورادیولوژیست‌ها تبدیل شود.

هدف نهایی دستیابی به روشی خودکار برای بخش‌بندی است که بتواند حجم بالای اطلاعات موجود در تصاویر ام‌آرآی را به‌طور کارآمد پردازش کند. هرچند طی سال‌های اخیر روش‌های خودکار زیادی برای این منظور پیشنهاد شده‌اند؛ اما هیچ‌یک از این روش‌ها به‌طور گسترده در کاربردهای بالینی پذیرفته نشده‌اند [۶].

امروزه به دلیل دقت بالا، مقاومت در برابر نویز و قابلیت تعمیم‌پذیری، از یادگیری عمیق برای بخش‌بندی تصاویر استفاده شده است. یادگیری عمیق به دلیل قابلیت تشخیص الگوهای پیچیده، انعطاف‌پذیری، امکان کار با داده‌های بزرگ در بسیاری از زمینه‌ها از جمله پردازش تصاویر مورد توجه قرار گرفته است.

در این مقاله به بررسی روش‌های یادگیری عمیق و معرفی معماری‌های مهم در بخش‌بندی پلاک‌های ام‌اس در تصاویر ام‌آرآی پرداخته می‌شود. این روش‌ها قادر هستند ویژگی‌های پیچیده تصاویر پزشکی را به‌صورت خودکار استخراج کنند و بدون نیاز به طراحی دستی، فرآیند بخش‌بندی پلاک‌ها را با دقت بالا انجام دهند. هم‌چنین مقایسه‌ای کیفی و کمی از آن‌ها ارائه شده و نقاط قوت و ضعف هر یک بررسی شده است. هدف این مقاله، شناسایی جهت‌گیری‌های پژوهشی آینده در حوزه بخش‌بندی پلاک‌های ام‌اس است.

ساختار این مقاله به این صورت تنظیم شده است: در بخش دوم، مجموعه دادگان عمومی مربوط به پلاک‌های ام‌اس و رایج‌ترین معیارهای ارزیابی مورداستفاده در پژوهش‌ها معرفی می‌شوند. پس از آن به بررسی معماری‌های یادگیری عمیق به‌کاررفته در بخش‌بندی خودکار پلاک‌های ام‌اس می‌پردازد. در ادامه بخش دوم معماری‌های U-Net، ResUNet و AttentionUNet مورد بررسی قرار می‌گیرند. در بخش سوم، مقایسه‌ای کیفی و کمی از عملکرد روش‌ها ارائه می‌شود. در نهایت در بخش پنجم،

<sup>1</sup> Systematic Literature Review (SLR)



بیماران مبتلا به ام‌اس و افراد سالم را شامل می‌شود. مجموعه شامل ۲۰ داده آموزش با برچسب و ۲۵ داده بدون برچسب برای آزمون است. تصاویر در نمای Axial و با فرمت .nii ارائه شد و دسترسی به آن نیازمند ثبت‌نام و احراز هویت است [۷، ۸].

▪ **ISBI 2015 Challenge Dataset**: این مجموعه دادگان در قالب چالش ISBI 2015 منتشر شد و شامل ۵ مورد برای آموزش و ۱۴ مورد برای آزمون است. برای هر نمونه، تصاویر ام‌آرآی در توالی‌های T1-weighted، T2-weighted، PD-weighted و FLAIR موجود است. تمامی تصاویر با فرمت .nii ارائه شده‌اند و به صورت گسترده در پژوهش‌های مبتنی بر یادگیری عمیق استفاده شده‌اند [۹].

▪ **MICCAI MSSEG 2016**: این مجموعه دادگان شامل داده‌های ام‌آرآی از ۵۳ بیمار مبتلا به ام‌اس است که از سه مرکز تصویربرداری مختلف در فرانسه گردآوری شده است. داده‌ها در مدالیته‌های FLAIR، T1 و T2 و با فرمت .nii موجود هستند. میانگین سنی بیماران ۴۵/۴ سال و بازه سنی بین ۲۴ تا ۶۱ سال است. ۳۸ نفر از شرکت‌کنندگان زن و ۱۵ نفر مرد بوده‌اند. دریافت این مجموعه دادگان پس از ثبت‌نام امکان‌پذیر است [۱۰].

▪ **MICCAI MSSEG 2021**: جدیدترین چالش در زمینه بخش‌بندی پلاک‌های ام‌اس در سال ۲۰۲۱ برگزار شده است. این مجموعه شامل تصاویر ام‌آرآی مربوط به ۱۰۰ بیمار مبتلا به ام‌اس است که توسط چندین مرکز تصویربرداری فراهم شده‌اند. تصاویر در فرمت .nii ارائه شده و دارای برچسب‌های دقیق پلاک‌های ام‌اس تهیه‌شده توسط چند متخصص هستند. این مجموعه به صورت گسترده برای ارزیابی تعمیم‌پذیری مدل‌های یادگیری عمیق استفاده می‌شود [۱۱].

▪ **Brain MRI Dataset of Multiple Sclerosis**: این مجموعه دادگان توسط مسلم و همکاران در سال ۲۰۲۲ از شهر بغداد عراق تهیه و در مجله Data in Brief منتشر شده است. داده‌ها شامل تصاویر ام‌آرآی با توالی‌های T1-

تمركز بر دقت در بخش‌بندی پلاک‌ها، انتخاب شدند. سپس مقاله‌های تکراری یا فاقد کیفیت علمی کافی، مقاله‌های بدون داده عددی قابل مقایسه و پژوهش‌هایی که به طور خاص بر شناسایی یا طبقه‌بندی تمرکز داشته‌اند حذف شدند.

۴- **انتخاب نهایی مقاله‌ها**: پس از اعمال مراحل غربال‌گری اولیه و بررسی دقیق محتوای علمی در نهایت ۳۴ مقاله مرتبط با هدف پژوهش انتخاب شدند. این مقاله‌ها به صورت کیفی و کمی مورد ارزیابی قرار گرفتند.

بررسی این مقاله‌ها نشان می‌دهد که فرآیند شناسایی و تحلیل پلاک‌های ام‌اس به طور معمول شامل مراحل زیر است:

- جمع‌آوری داده‌ها از طریق تصویربرداری ام‌آرآی و مجموعه دادگان مرتبط
- پیش‌پردازش تصاویر شامل تنظیم شدت، نرمال‌سازی و حذف نویز
- استخراج ویژگی‌ها مانند بافت، شدت، شکل و موقعیت
- در نهایت بخش‌بندی نواحی آسیب‌دیده با استفاده از مدل‌های هوشمند

تمرکز اصلی این مقاله تحلیل معماری‌های یادگیری عمیق در مرحله بخش‌بندی تصاویر است. در این راستا سه مدل U-Net، ResUNet و AttentionUNet که در پژوهش‌های مختلف عملکرد بالایی در بخش‌بندی پلاک‌های ام‌اس داشته انتخاب و به صورت کیفی و کمی مورد بررسی دقیق و مقایسه قرار گرفتند.

## ۱-۲ مجموعه دادگان

در پژوهش‌های مربوط به شناسایی و بخش‌بندی پلاک‌های ام‌اس کمبود مجموعه دادگان عمومی<sup>۱</sup>، متنوع و دارای برچسب دقیق همواره به عنوان چالش مطرح بوده است. به همین دلیل، محققان از مجموعه دادگان مختلفی بهره گرفته‌اند که به طور مستقیم یا غیرمستقیم به پلاک‌های مغزی در بیماران مبتلا به ام‌اس پرداخته‌اند. در ادامه مهم‌ترین مجموعه دادگان عمومی و رایج در این حوزه معرفی شده است.

▪ **MS Lesion Segmentation Challenge 2008**: این چالش در سال ۲۰۰۸ برگزار شد و داده‌های ام‌آرآی مربوط به

<sup>1</sup> Public



جدول (۱). مجموعه دادگان عمومی مورد استفاده در بخش‌بندی پلاک‌های ام‌اس

فرمت	توضیحات	مجموعه دادگان
.nii	تصاویر ام‌آرای از ۴۵ فرد بیمار	MS Lesion Segmentation Challenge 2008 [8]
.nii	تصاویر ام‌آرای از ۵ فرد برای آموزش و ۱۴ فرد برای آزمون	ISBI 2015 [9]
.nii	تصاویر ام‌آرای از ۵۳ فرد بیمار	MICCAI MSSEG 2016 [10]
.nii	۲۱۰ بیمار با تومور بدخیم و ۷۵ بیمار با تومور سطح پایین	BraTS 2018 [13]
.nii	تصاویر ام‌آرای از ۱۰۰ فرد بیمار	MICCAI MSSEG 2021 [11]
.nii	تصاویر ام‌آرای از ۶۰ بیمار	[12]

مهم‌ترین معیارهایی که در بیشتر پژوهش‌ها به کار رفته‌اند عبارت‌اند از:

- **Dice**: یکی از رایج‌ترین معیارها در ارزیابی دقت بخش‌بندی است که میزان هم‌پوشانی بین ناحیه پیش‌بینی شده توسط مدل و ناحیه واقعی (نشان داده شده در برجسب‌های دستی) را اندازه‌گیری می‌کند. مقدار آن در بازه [۰,۱] است. این مقدار هر چه به یک نزدیک‌تر باشد، نشان‌دهنده دقت بالاتر بخش‌بندی است. در رابطه ۱ نحوه محاسبه این معیار آورده شده است.

$$\text{Dice}(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

A مجموعه پیکسل‌های ناحیه پیش‌بینی شده و B مجموعه پیکسل‌های برجسب مرجع است.

- **IoU**: این معیار مشابه Dice عمل می‌کند؛ اما محاسبه آن متفاوت است. این معیار نسبت ناحیه مشترک بین پیش‌بینی و واقعیت را به مجموع این دو ناحیه اندازه می‌گیرد. نحوه محاسبه این معیار در رابطه ۲ آورده شده است.

$$\text{IoU}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

صورت کسر بیانگر پیکسل‌های مشترک بین دو ناحیه و مخرج کسر پیکسل‌های دو ناحیه است. مقدار بالاتر IoU نشان‌دهنده توانایی

FLAIR و T2-weighted, weighted مربوط به ۶۰ بیمار مبتلا به ام‌اس (۴۶ زن و ۱۴ مرد) با میانگین سنی ۳۳ سال (۱۵ تا ۵۶ سال) می‌باشند. تصاویر با فرمت .nii ارائه شده‌اند و توسط سه متخصص به صورت دستی بخش‌بندی شده‌اند. این مجموعه دارای اطلاعات بیش‌تر از جمله سن، جنسیت، نوع درمان و نمره ناتوانی بیماران است. تصاویر طی سال‌های ۲۰۱۹ تا ۲۰۲۰ و از ۲۰ مرکز تصویربرداری مختلف گردآوری شده‌اند. دسترسی به این مجموعه دادگان از طریق پایگاه Mendeley امکان‌پذیر است [۱۲].

- **BraTS<sup>1</sup>**: اگرچه مجموعه دادگان BraTS به‌طور خاص برای بیماران مبتلا به تومور مغزی طراحی شده است؛ اما به‌دلیل شباهت ماهیتی در نوع ضایعه‌ها و ساختار مغزی، در برخی پژوهش‌ها نیز برای الگوریتم‌های بخش‌بندی ام‌اس مورد استفاده قرار گرفته است. برای مثال، مجموعه دادگان BraTS 2018 شامل ۲۱۰ نمونه با تومور بدخیم و ۷۵ مورد با تومور سطح پایین است. تصاویر با فرمت .nii و در مدالیته‌های مختلف ام‌آرای ارائه شده‌اند. BraTS به‌عنوان یکی از مجموعه دادگان گسترده و معتبر در حوزه تصویربرداری پزشکی شناخته می‌شود [۱۳].

در جدول ۱ خلاصه‌ای از مهم‌ترین مجموعه دادگان مورد استفاده در بخش‌بندی پلاک‌های بیماری ام‌اس به همراه مشخصات کلیدی آن‌ها ارائه شده است. این مجموعه دادگان پایه‌ای برای ارزیابی و مقایسه عملکرد مدل‌های یادگیری عمیق در این حوزه محسوب می‌شوند.

## ۲-۲ معیارهای ارزیابی

در ارزیابی عملکرد مدل‌های یادگیری عمیق برای بخش‌بندی پلاک‌های ام‌اس در تصاویر ام‌آرای مغزی، استفاده از معیارهای دقیق و تخصصی ضروری است.

<sup>1</sup> Brain Tumor Segmentation (BraTS)

در روابط TP نشان‌دهنده پیکسل‌های صحیح بخش‌بندی شده، FP و FN نشان‌دهنده پیکسل‌هایی با بخش‌بندی نادرست و TN نشان دهنده پیکسل‌های صحیح بخش‌بندی شده هستند.

## ۲-۳ معماری‌های مورد بررسی

یادگیری عمیق به‌عنوان یکی از رویکردهای پیشرو در حوزه بینایی ماشین و پردازش تصاویر پزشکی شناخته شده است. مدل‌های یادگیری عمیق با استفاده از لایه‌های متعدد و ساختارهای پیچیده، توانستند ویژگی‌های سطح پایین و بالا را به‌صورت خودکار از داده‌ها استخراج کرده و عملکرد چشم‌گیری در وظایف مختلف مانند طبقه‌بندی، تشخیص و به‌ویژه بخش‌بندی تصاویر پزشکی ارائه دهند. یکی از عوامل کلیدی در موفقیت این مدل‌ها، طراحی معماری مناسب متناسب با مسئله مورد نظر است. معماری‌های مختلفی در زمینه بخش‌بندی تصاویر ام‌آرآی در بیماران مبتلا به ام‌اس توسعه یافتند که هر یک با هدف بهبود دقت، کاهش پیچیدگی محاسباتی یا افزایش تمرکز مدل بر نواحی مهم طراحی شدند.


در این بخش سه معماری پرکاربرد U-Net، ResUNet و AttentionUNet مورد بررسی قرار می‌گیرند. این مدل‌ها به‌ترتیب، پایه‌ای‌ترین ساختار برای بخش‌بندی تصاویر، نسخه تقویت‌شده با اتصالات باقی‌مانده و معماری مبتنی بر مکانیزم توجه هستند که در تحقیق‌های اخیر به‌طور گسترده در بخش‌بندی پلاک‌های ام‌اس به کار رفته است.

### معماری U-Net

معماری U-Net برای اولین بار در سال ۲۰۱۵ توسط رونبرگر و همکارانش برای بخش‌بندی معنایی تصاویر پزشکی معرفی شد [۱۶]. معماری U-Net تاکنون در حوزه‌هایی مانند پردازش تصاویر ام‌آرآی و سی‌تی‌اسکن در کاربردهای تشخیص ضایعه‌ها و ناهنجاری‌ها، عملکرد خوبی از خود نشان داده است. ساختار این معماری در شکل ۴ آورده شده است. نام U-Net از شکل U مانند ساختار آن گرفته شده است. معماری U-Net از دو بخش اصلی

بیش‌تر مدل در شناسایی مرزهای دقیق پلاک‌های ام‌اس است. در شکل ۳ نحوه محاسبه و تفاوت معیارهای Dice و IoU آورده شده است.

سایر معیارهای رایج در برخی مطالعات شامل دقت، بازخوانی<sup>۱</sup>، صحت<sup>۲</sup>، اختصاصی بودن<sup>۳</sup> و امتیاز F1 هستند. تمرکز اصلی در ارزیابی بخش‌بندی پلاک‌های مغزی به‌طور معمول بر روی Dice و IoU قرار دارد، به این دلیل که این دو معیار به‌طور مستقیم به‌دقت هندسی ناحیه تشخیص یافته مرتبط هستند [۱۴].



شکل (۳): مقایسه معیارهای امتیاز Dice و IoU [۱۵]

در جدول ۲ خلاصه‌ای از معیارهای ارزیابی عملکرد در بخش‌بندی پلاک‌های مغزی در تصاویر ام‌آرآی آورده شده است.

جدول (۲): معیارهای ارزیابی مورد استفاده در بخش‌بندی پلاک‌های ام‌اس

معیار ارزیابی	نحوه محاسبه	توضیح
Dice	$\frac{2  A \cap B }{ A  +  B }$	اندازه‌گیری همپوشانی ناحیه پیش‌بینی شده و ناحیه واقعی
IoU	$\frac{ A \cap B }{ A \cup B }$	دقت در تشخیص نواحی مشترک نسبت به کل نواحی پیش‌بینی شده و واقعی
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$	نسبت پیش‌بینی‌های درست به کل نمونه‌ها
Recall	$\frac{TP}{TP + FN}$	توانایی مدل در شناسایی درست نواحی آسیب‌دیده
Precision	$\frac{TP}{TP + FP}$	درصد پیش‌بینی‌های درست در میان تمام پیش‌بینی‌های مثبت مدل
Specificity	$\frac{TN}{TN + FP}$	توانایی مدل در تشخیص صحیح نواحی سالم
F1-Score	$\frac{2 \times \text{Recall} \times \text{Precision}}{\text{Precision} + \text{Recall}}$	میانگین هارمونیک بازخوانی و صحت

<sup>۴</sup> Specificity

<sup>۱</sup> Accuracy

<sup>۲</sup> Recall

<sup>۳</sup> Precision

مکانی را به‌طور مستقیم از لایه‌های اولیه رمزگذار به لایه‌های متناظر در رمزگشا منتقل می‌کنند. این طراحی باعث حفظ جزئیات ساختاری و مرزهای ناحیه‌ای می‌شود که برای بخش‌بندی ضایعه‌های کوچک مانند پلاک‌های ام‌اس مهم است.

از مزایای معماری U-Net می‌توان به سادگی ساختار، قابلیت آموزش با داده‌های محدود، دقت بالا در شناسایی مرزهای ناحیه‌ای و انعطاف‌پذیری در تطبیق با معماری‌های پیچیده‌تر اشاره کرد. به همین دلیل U-Net به‌عنوان معماری پایه در بسیاری از مطالعه‌های مرتبط با بخش‌بندی ضایعه‌های مغزی و سایر ساختارهای پزشکی به‌کار رفته است. از این معماری توسعه‌هایی مانند ResUNet، AttentionUNet، U<sup>2</sup>-Net و U-Net++ نیز ایجاد شده‌است [۱۷، ۱۸].


جدول ۳ گزیده‌ای از پژوهش‌های انجام‌شده را مرور می‌کند که در آن‌ها از معماری U-Net به‌عنوان چارچوب اصلی برای بخش‌بندی پلاک‌های ناشی از بیماری ام‌اس در تصاویر ام‌آرآی بهره گرفته شده است. لازم به ذکر است در جدول‌های ارائه شده مواردی که با خط تیره نشان داده شده است در مقاله مربوطه گزارش نشده است.

#### ▪ معماری ResUNet

معماری ResUNet با هدف ترکیب مزایای یادگیری عمیق با ساختار U-Net توسعه یافته است. این معماری برای اولین بار توسط ژانگ و همکارانش در سال ۲۰۱۸ برای استخراج جاده‌ها از تصاویر هوایی معرفی شد [۲۴].

ساختار کلی ResUNet مشابه U-Net است؛ اما به‌جای بلوک‌های کانولوشنی ساده از واحدهای باقی‌مانده ۴ استفاده می‌کند. این تغییر باعث می‌شود که آموزش شبکه‌های عمیق آسان‌تر شده و عملکرد بهتری با تعداد کم‌تری از پارامترها حاصل شود. ساختار معماری ResUNet در شکل ۵ نمایش داده شده است.

رمزگذار<sup>۱</sup> یا مسیر کاهشی و رمزگشا<sup>۲</sup> یا مسیر افزایشی تشکیل شده است.



شکل (۴): معماری U-Net [۱۶]

رمزگذار متشکل از چندین بلوک کانولوشنی متوالی است که وظیفه استخراج ویژگی‌های سطح پایین تا سطح بالا را از تصویر ورودی بر عهده دارد. در هر بلوک، ابتدا دو یا چند عملیات کانولوشن همراه با توابع فعال‌سازی به‌طور معمول ReLU انجام می‌شود. سپس با استفاده از عملیات Max-pooling اندازه مکانی تصویر کاهش می‌یابد تا مدل بتواند اطلاعات مهم‌تری را استخراج کرده و پیچیدگی محاسباتی نیز کاهش یابد. با پیشروی در این مسیر، ابعاد مکانی تصویر کوچک‌تر و تعداد کانال‌های ویژگی افزایش می‌یابد. در رمزگشا، عملیات به‌صورت معکوس انجام می‌شود. از طریق کانولوشن معکوس یا عملیات نمونه‌برداری بالا، ابعاد مکانی نقشه ویژگی به‌تدریج افزایش می‌یابد تا خروجی نهایی با ابعاد تصویر اولیه مطابقت پیدا کند. در هر مرحله از مسیر رمزگشا، ویژگی‌های بازسازی‌شده با ویژگی‌های متناظر از مسیر رمزگذار از طریق اتصال‌های پرشی ترکیب می‌شوند. این اتصال‌ها، اطلاعات دقیق

<sup>3</sup> Skip Connections

<sup>4</sup> Residual

<sup>1</sup> Encoder

<sup>2</sup> Decoder

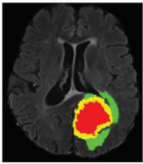
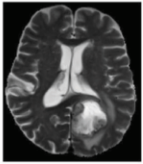
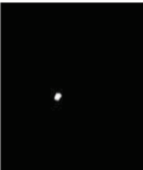
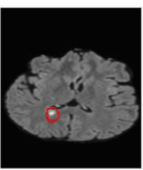

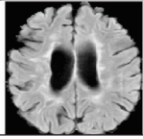

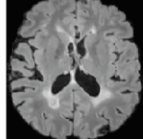

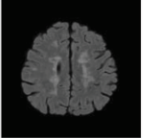




جدول (۳): گزیده‌ای از پژوهش‌های انجام شده برای بخش‌بندی پلاک‌های ام‌اس در تصاویر ام‌آرآی با استفاده از معماری U-Net

نویسندگان	سال انتشار	مجموعه دادگان	Recall	Precision	F1-Score	Dice	مرحله پیش‌پردازش / استخراج ویژگی	نقاط ضعف / قوت	تصویر ورودی	تصویر خروجی
کومار و همکاران [۱۹]	۲۰۱۹	MICCAI MSSEG 2016	۰/۷۷۲	-	-	۰/۸۰۳	تبدیل تصاویر سه‌بعدی به برش‌های دوبعدی، حذف برش‌های خالی، نرمال‌سازی، افزایش داده، استفاده از Dense Block برای تقویت استخراج ویژگی	کار کردن با برش‌های دوبعدی و هدر رفت بخشی از اطلاعات نسبت به تصاویر سه‌بعدی، قابلیت تعمیم کم‌تر		
اصلانی و همکاران [۲۰]	۲۰۱۹	ISBI2015	-	۰/۸۹۹۲	-	۰/۶۱۱۴	هم‌تراز سازی، حذف مجموعه، نرمال‌سازی شدت	استفاده از ترکیب سه مدالیته مختلف از تصاویر، زمان اجرای بالا با توجه به کار با تصاویر سه‌بعدی، نیاز به منابع محاسباتی بالا		
سالم و همکاران [۲۱]	۲۰۱۹	ISBI2015	۰/۵۷	۰/۷۹	-	۰/۶۴	ساخت پرچسب‌هایی برای شدت پلاک‌ها، ترکیب این پرچسب‌ها با تصاویر اصلی برای ورود به شبکه	بدون نیاز به پرچسب‌زنی، مناسب برای داده با پرچسب کم، دقت پایین روی داده واقعی		
علی‌جماعت و همکاران [۲۲]	۲۰۲۱	MICCAI MSSEG 2016	-	۰/۷۶۲	-	۰/۸۲۴	تبدیل تصاویر سه‌بعدی به برش‌های دوبعدی، حذف برش‌های خالی، تغییر اندازه تصاویر به ۲۵۶x۲۵۶، نرمال‌سازی پیکسل‌ها و افزایش داده، استفاده از تبدیل موجک برای استخراج ویژگی‌های محلی و کاهش ابعاد	کار کردن با برش‌های دوبعدی و هدر رفت بخشی از اطلاعات نسبت به تصاویر سه‌بعدی، حساسیت به نوع تبدیل موجک انتخاب‌شده		
اشتری و همکاران [۲۳]	۲۰۲۲	MICCAI MSSEG 2021	۰/۴۷۵	۰/۵۳۶	۰/۴۸۱	۰/۴۰۳	ترکیب دو تصویر FLAIR به‌عنوان ورودی سه‌بعدی، حذف نواحی صفر و همسان‌سازی شدت تصاویر، نرمال‌سازی با Z-score افزایش داده	دشواری در تشخیص پلاک‌های کوچک یا مبهم، نیاز بالا به منابع پردازشی و وابستگی به داده‌های زیاد برای آموزش مؤثر		
میانگین	-	-	۰/۶۰۵۶	۰/۷۴۶۸	۰/۴۸۱	۰/۶۵۶۲	-	-	-	-



جدول (۴): گزیده‌ای از پژوهش‌های انجام شده برای بخش‌بندی پلاک‌های ام‌اس در تصاویر آم‌آری با استفاده از معماری ResUNet

تصویر خروجی	تصویر ورودی	نقاط ضعف/ قوت	مرحله پیش‌پردازش/ استخراج ویژگی	Dice	F1-Score	Precision	Recall	مجموعه دادگان	سال انتشار	نویسندگان
		کار کردن با برش‌های دوبعدی و هدررفت بخشی از اطلاعات نسبت به تصاویر سه‌بعدی، استفاده از Cross Entropy Loss ساده به جای Dice Loss	تبدیل تصاویر به برش‌های دوبعدی، نرمال‌سازی، افزایش داده، استفاده از U-Net با ۱۰۴ لایه برای استخراج ویژگی	۰/۶۷۵۶	-	-	-	BraTs2020	۲۰۲۱	کلمن و همکاران [۲۵]
		عملکرد مناسب در داده‌های جمع‌آوری شده از مراکز مختلف، ضعف در تشخیص پلاک‌های کوچک، هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی، گزارش نکردن معیارهای دیگر ارزیابی	تبدیل تصاویر به برش‌های دوبعدی، حذف حجم، نرمال‌سازی شدت، انتخاب برش‌های دارای پلاک، افزایش داده	-	۰/۴۸	-	-	MICCAI MSSEG 2021	۲۰۲۲	ساریکا و همکاران [۲۶]
		ضعف نسبی در کار با داده‌های جمع‌آوری شده از مراکز که تاکنون مدل آن‌ها را ندیده، ضعف در تشخیص دقیق حجم پلاک‌های کوچک، هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی	استخراج برش‌های دوبعدی از تصاویر، نرمال‌سازی شدت، حذف حجم، استفاده از برش‌های دارای پلاک، تغییر اندازه به ۲۲۴x۲۲۴ افزایش داده	۰/۶۶۸۸	-	۰/۸۶۵۰	-	ISBI2015	۲۰۲۳	ساریکا و همکاران [۲۷]
				۰/۶۷۲۷	۰/۵۸۸۳	۰/۶۵۱۹	-	MICCAI MSSEG 2016		
		هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی	تبدیل تصاویر به برش‌های دوبعدی، تغییر اندازه به ۵۱۲x۵۱۲ افزایش کنتراست با CLAHE	۰/۸۱۳۵	-	-	۰/۸۹۲۸	مجموعه دادگان خصوصی <sup>۱</sup>	۲۰۲۴	راجاسکار و همکاران [۲۸]
		استفاده از یادگیری انتقالی، هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی	تبدیل تصاویر به برش‌های دوبعدی، حذف نویز، افزایش داده	۰/۶۳۸	-	۰/۶۸۷	۰/۶۹۴	MICCAI MSSEG 2016	۲۰۲۴	گانپولا و همکاران [۲۹]
-	-			۰/۶۹۳۷	۰/۵۳۴۱	۰/۷۳۴۶	۰/۷۹۳۴	-	-	میانگین

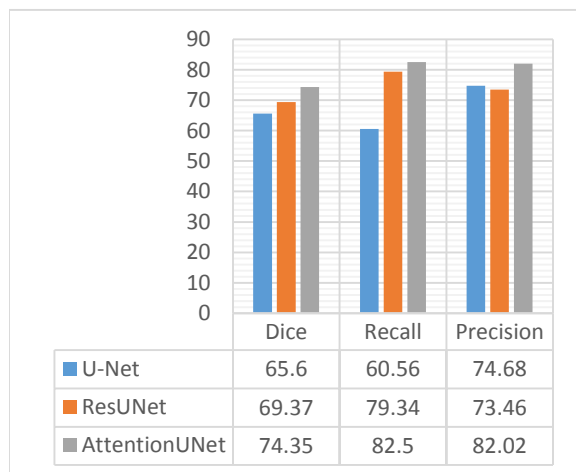
می‌شود که تعیین می‌کند کدام بخش‌های ویژگی‌ها باید بیش‌تر و کدام بخش‌ها باید کم‌تر مورد توجه واقع شوند.

از جمله مزایای اصلی AttentionUNet می‌توان به موارد زیر اشاره کرد:

- افزایش تمرکز شبکه بر روی نواحی با اهمیت بالاتر
- بهبود دقت در بخش‌بندی ضایعه‌های کوچک و نواحی مرزی
- کاهش تأثیر نواحی غیرمرتبط و نویز در تصاویر پزشکی
- انعطاف‌پذیری بالا در تطبیق با انواع مختلف داده‌های پزشکی با توجه به این ویژگی‌ها، معماری AttentionUNet به‌ویژه در بخش‌بندی پلاک‌های کوچک ناشی از بیماری ام‌اس در تصاویر ام‌آرآی کارایی بالایی از خود نشان داده است. جدول ۵ گزیده‌ای از پژوهش‌هایی که از این معماری در زمینه شناسایی پلاک‌های ام‌اس بهره گرفته‌اند را مرور می‌کند.

### ۳- نتایج و تحلیل

در این بخش، نتایج حاصل از مرور مقاله‌هایی که از معماری‌های U-Net، ResUNet و AttentionUNet برای بخش‌بندی پلاک‌های بیماری ام‌اس در تصاویر ام‌آرآی استفاده کرده‌اند، ارائه و تحلیل می‌شود. در شکل ۷ عملکرد هر یک از این معماری‌ها بر اساس معیارهای رایج ارزیابی Dice، بازخوانی و صحت را نشان می‌دهد.

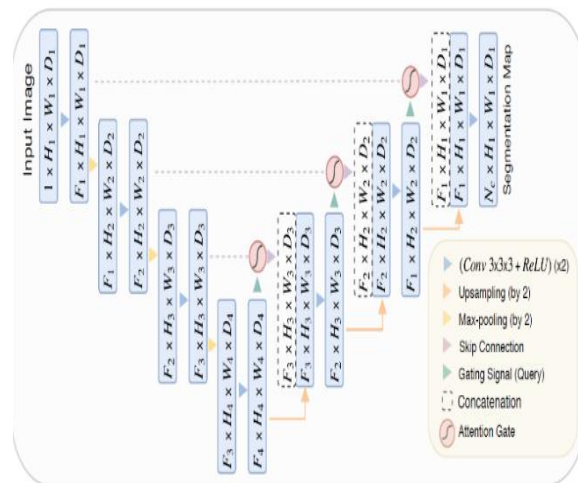


شکل (۷): مقایسه عملکرد معماری‌ها

### معماری AttentionUNet

معماری AttentionUNet توسعه‌ای بر پایه U-Net است که برای بهبود فرآیند بخش‌بندی تصاویر پزشکی، به‌ویژه در تشخیص نواحی با اهمیت بالا طراحی شده است. این معماری برای نخستین بار توسط اوکتای و همکارانش در سال ۲۰۱۸ معرفی شد [۳۰].

ایده اصلی AttentionUNet استفاده از مکانیزم توجه برای تقویت نواحی مرتبط با هدف در تصاویر ورودی و تضعیف نواحی نامرتبط است به‌طوری که شبکه بتواند تمرکز بیشتری بر روی بخش‌های مهم تصویر داشته باشد. ساختار این معماری در شکل ۶ نمایش داده شده است.

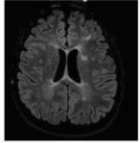
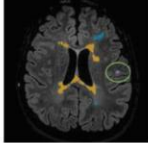
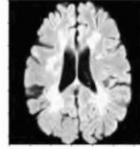

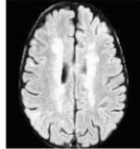

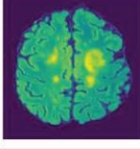



شکل (۶): معماری AttentionUNet [۳۰]

در ساختار AttentionUNet، مشابه با U-Net در مسیر رمزگذار ویژگی‌های سطح پایین استخراج می‌شوند؛ اما در مسیر رمزگشا به‌جای اتصال مستقیم ویژگی‌های مسیر کاهشی به ویژگی‌های بازسازی شده، ابتدا این اطلاعات از طریق بلوک‌های توجه عبور داده می‌شوند. این بلوک‌های توجه به‌طور خودکار نواحی مهم تصویر را شناسایی کرده و انتقال اطلاعات غیرمفید را محدود می‌کنند. این طراحی کمک می‌کند تا دقت بخش‌بندی به‌ویژه در تصاویر با نواحی کوچک یا دارای نویز پس‌زمینه افزایش یابد.

مکانیزم توجه در این معماری به‌صورت تطبیقی عمل می‌کند، به این صورت که برای هر ناحیه از تصویر یک نقشه وزن‌دهی محاسبه

جدول (۵): گزیده‌ای از پژوهش‌های انجام شده برای بخش‌بندی پلاک‌های ام‌اس در تصاویر ام‌آرآی با استفاده از معماری AttentionUNet

نویسندگان	سال انتشار	مجموعه دادگان	Recall	Precision	F1-Score	Dice	مرحله پیش‌پردازش / استخراج ویژگی	نقاط ضعف/ قوت	تصویر ورودی	تصویر خروجی
هو و همکاران [۳۱]	۲۰۲۰	ISBI2015	-	۰/۸۶۸۲	-	۰/۶۳۴۵	استفاده از ۴ مدالیته ام‌آرآی، برش حجم‌ها به $۱۶۰ \times ۱۹۲ \times ۱۶۰$ ، افزایش داده، استخراج ویژگی با معماری سه‌بعدی ACU-Net شامل ماژول context-guided و بلوک توجه برای تشخیص مناسب پلاک	پیچیدگی محاسباتی بالا به دلیل استفاده از تصاویر سه‌بعدی و ماژول توجه، احتمال افت عملکرد روی داده‌های جدید، عدم ارائه تصاویر خروجی مدل	-	-
راکبک و همکاران [۱]	۲۰۲۱	مجموعه دادگان خصوصی	-	-	-	۰/۶۴	استفاده از تصاویر دو مدالیته T1 و FLAIR، نرمال‌سازی شدت، حذف جمجمه، ورودی دوکاناله به-U-Net سه‌بعدی با ترکیب یادگیری بدون ناظر برای بهبود تشخیص پلاک‌های کوچک و پیچیده	عملکرد مناسب در داده واقعی جمع‌آوری شده از چند مرکز، ترکیب روش‌های کلاسیک و عمیق، دقت کم‌تر روی بیماران با پلاک کوچک، پیچیدگی مدل بالا		
هاشمی و همکاران [۳۲]	۲۰۲۲	ISBI2015	۰/۸۶۵۰	۰/۷۹۲۶	-	۰/۸۲۳۰	ورودی تصاویر FLAIR و T2، تبدیل تصاویر سه‌بعدی به برش‌های دوبعدی، حذف برش‌های بدون پلاک، برش به‌اندازه $۱۲۸ \times ۱۲۸$ ، استفاده از U-Net و Attention U-Net دوبعدی با تابع زیان ترکیبی DSC و Cross-Entropy	هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی		
راندینلا و همکاران [۳۳]	۲۰۲۳	ISBI2015	۰/۸۶	۰/۹۱	-	۰/۸۹	ورودی تصاویر FLAIR، تبدیل تصاویر سه‌بعدی به برش‌های دوبعدی، برش به‌اندازه $۱۶۰ \times ۱۶۰$ ، استخراج ویژگی با ماژول‌های squeeze-attention	هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی، افزایش داده انجام نشده است		
گسل و همکاران [۳۴]	۲۰۲۴	MICCAI MSSEG 2016	۰/۷۵	۰/۷۱	-	۰/۷۳	تبدیل تصاویر به دوبعدی، تغییر اندازه به $۲۵۶ \times ۲۵۶$ ، استخراج ویژگی با دو مسیر U-Net با مکانیزم توجه	ساختار پیچیده، هدررفت بخشی از اطلاعات نسبت به کار با تصاویر سه‌بعدی،		
میانگین	-	-	۰/۸۲۵	۰/۸۲۰۲	-	۰/۷۴۳۵			-	-

مدیریت نویز یا نواحی کوچک موجب شده است که عملکرد آن در مقایسه با نسخه‌های بهبود یافته محدودتر باشد. ResUNet با بهره‌گیری از بلوک‌های باقی‌مانده توانسته است مشکل‌هایی نظیر ناپدید شدن گرادیان را کاهش دهد و فرآیند آموزش را در شبکه‌های عمیق‌تر پایدارتر کند. این موضوع در داده‌هایی با ساختار پیچیده‌تر موجب بهبود جزئی در دقت بخش‌بندی نسبت به U-Net شده است. ResUNet در بعضی پژوهش‌ها عملکردی مشابه یا کمی بهتر از U-Net داشته و در مقابل معماری AttentionUNet عملکرد بالاتری نشان داده است. تفاوت نتایج بین مقاله‌های مختلف ممکن است به عواملی مانند نوع مجموعه دادگان، پیش‌پردازش داده‌ها، تنظیم‌های آموزش و انتخاب معیارهای ارزیابی نیز مرتبط باشد. به‌طور خاص، مجموعه دادگان دارای پلاک‌های کوچک و بی‌نظم، تأثیر قابل‌توجهی بر نتایج به دست آمده داشته‌اند.

نتایج مرور شده در این مقاله نشان می‌دهند که توسعه معماری‌های مبتنی بر توجه یا استفاده از ساختارهای بهینه‌تر در مسیرهای رمزگذار و رمزگشا می‌تواند به بهبود قابل‌توجه در دقت بخش‌بندی پلاک‌های ام‌اس منجر شود. این یافته‌ها مسیرهای مناسبی را برای پژوهش‌های آینده در زمینه بهبود بخش‌بندی تصاویر پزشکی مبتنی بر یادگیری عمیق فراهم می‌کنند.

با بررسی نتایج می‌توان مشاهده کرد که در اغلب مطالعات، معماری AttentionUNet نسبت به U-Net و ResUNet عملکرد بهتری در بخش‌بندی داشته است. این بهبود به دلیل استفاده از مکانیزم توجه است که امکان تمرکز بیشتر بر نواحی مرتبط با پلاک‌ها را فراهم می‌کند. در جدول ۶ مقایسه کلی از معماری‌ها و مزایا و معایب هر یک آورده شده است.

با توجه به اینکه پژوهش‌های موردبررسی در این مطالعه از مجموعه دادگان مختلفی شامل پایگاه‌های داده عمومی و خصوصی استفاده کرده‌اند که برخی از آن‌ها غیرقابل دسترسی هستند امکان انجام مقایسه به‌طور کامل هم‌سطح بین عملکرد معماری‌ها وجود نداشته است. تفاوت در ویژگی‌های داده‌ها از جمله اندازه و تعداد پلاک‌ها، میزان نویز، کیفیت تصویر و حجم داده‌های آموزشی بر نتایج حاصل از هر مدل تأثیرگذار است.

هدف از ارائه میانگین عملکرد معماری‌ها در جدول ۶، ایجاد یک دید کلی نسبت به روندهای گزارش‌شده در پژوهش‌های پیشین بوده است. تحلیل انجام‌شده می‌تواند به‌عنوان مرجعی مفید برای درک نقاط قوت و ضعف معماری‌های مختلف و جهت‌دهی به پژوهش‌های آتی مورد استفاده قرار گیرد.

U-Net به‌عنوان معماری پایه عملکرد مناسبی در بخش‌بندی ضایعه‌ها نشان می‌دهد، به‌ویژه در شرایطی که داده‌های آموزشی محدود هستند. با این حال، عدم وجود مکانیزم‌های پیچیده برای

جدول (۶): مقایسه معماری‌های بررسی شده

معماری	ساختار اصلی	مزایا	معایب	میانگین معیار Dice	ویژگی
U-Net	مسیر رمزگذار/رمزگشا با اتصال‌های پرش	سادگی، نیاز به داده کمتر	ضعف در تشخیص پلاک‌های کوچک	۰/۶۵۶	معماری پایه بخش‌بندی تصاویر پزشکی
ResUNet	U-Net + بلوک‌های باقی‌مانده	پایداری آموزش، استخراج بهتر ویژگی‌ها	افزایش پیچیدگی نسبت به U-Net	۰/۶۹۳۷	کاهش مشکل ناپدید شدن گرادیان
AttentionUNet	U-Net + مکانیزم توجه	تمرکز بر نواحی مهم، دقت بالاتر	افزایش زمان محاسباتی	۰/۷۴۳۵	تقویت نواحی هدف در تصویر

در مجموع ۳۴ مقاله معتبر تحلیل گردید. نتایج نشان داد که معماری U-Net به‌واسطه سادگی و قابلیت آموزش با داده‌های محدود، در بسیاری از کاربردها مؤثر عمل کرده است. ResUNet با بهره‌گیری از بلوک‌های باقی‌مانده، انتقال مؤثرتر اطلاعات و دقت بالاتری در

#### ۴- نتیجه‌گیری

در این مقاله، عملکرد سه معماری یادگیری عمیق U-Net، ResUNet و AttentionUNet برای بخش‌بندی پلاک‌های بیماری ام‌اس در تصاویر ام‌آرآی به‌صورت مروری بررسی شد.



ترانسفورمرها برای بهبود عملکرد ادامه یابد. ادغام داده‌های تصویری و بالینی، گام مؤثری در جهت ارتقاء سیستم‌های تشخیصی هوشمند خواهد بود.

شناسایی پلاک‌های پراکنده فراهم می‌کند. AttentionUNet نیز با استفاده از مکانیزم توجه، دقت مدل را در داده‌های نامتوازن و پلاک‌ها با مرزهای نامشخص افزایش داده است. آینده این حوزه می‌تواند با تمرکز بر مدل‌های ترکیبی، توسعه معماری‌های سبک‌تر، بهره‌گیری از یادگیری انتقالی و استفاده از

## References

- [1] M. Rakić, S. Verduyssen, S. Eindhoven and E. Rosa, "Icobrain ms 5.1: combining unsupervised and supervised approaches for improving the detection of multiple sclerosis lesions," *NeuroImage. Clinical*, vol. 31, p. 102707, 2021
- [2] N. Aslam, I. Khan, A. Bashamakh and F. Alghool, "Multiple sclerosis diagnosis using machine learning and deep learning: challenges and opportunities," *Sensors*, vol. 22, no. 20, p. 7856, 2022.
- [3] Definition of MS. (2025, June. 7). [Online]. Available: <https://dr-moradi.com>.
- [4] A. Alijamaat, A. NikravanShalmani and P. Bayat, "Multiple sclerosis identification in brain MRI images using wavelet convolutional neural networks," *International Journal of Imaging Systems and Technology*, 2020.
- [5] NeuroMS. (2023, May. 11). [Online]. Available: <https://royancell.ir/NeuroMSCellT.html>.
- [6] M. Moghadasi and G. Fazekas, "Segmentation of MRI images to detect multiple sclerosis using non-parametric, non-uniform intensity normalization and support vector machine methods," *Infocommunications journal*, vol. 13, no. 1, pp. 68–74, 2021.
- [7] NeuroImaging Tools and Resources Collaboratory. (Accessed 16 May 2023) [Online]. Available: <https://www.nitrc.org/projects/msseg/>.
- [8] M. Styner, J. Lee, B. Chin, M. Commowick and C. Olivier, "3D segmentation in the clinic: a grand challenge II: MS lesion segmentation," *Researchgate*, 2008.
- [9] A. Carass, R. Sneathis, J. Amod and C. Jennifer, "Longitudinal multiple sclerosis lesion segmentation data resource," *Data in Brief*, vol. 12, pp. 346–350, 2017
- [10] O. Commowick, K. Michaël, C. Romain, "Multiple sclerosis lesions segmentation from multiple experts: The MICCAI 2016 challenge dataset," *NeuroImage*, vol. 244, p. 118589, 2021
- [11] "shanoir," *Irisa.fr*, (2023, May. 11) [Online]. Available: <https://shanoir.iris.fr/shanoir-ng/welcome>.
- [12] A. M. Muslim, "Brain MRI dataset of multiple sclerosis with consensus manual lesion segmentation and patient meta information," *data.mendeley.com*, vol. 1, 2022.
- [13] Center for Biomedical Image Computing & Analytics, (Accessed 16 May 2023). [Online]. Available: <http://braintumorsegmentation.org/>.
- [14] L. Baskaran, S. Al'Aref, G. Maliakal, "Automatic segmentation of multiple cardiovascular structures from cardiac computed tomography angiography images using deep learning," *plosone*, vol. 15, no. 5, 2020.
- [15] Dice coefficient, *IOU*. (2025, June. 7). [Online]. Available: <https://karan-jakhar.medium.com>.
- [16] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: convolutional networks for biomedical image segmentation," *Lecture Notes in Computer Science*, vol. 9351, pp. 234–241, 2015
- [17] R. Nair, T. Babu, G. Ramasamy, T. Singh and X. Yuan, "Advanced U-Net++ architecture for precise brain tumor segmentation in MRI images: A robust solution for medical image analysis," in *2024 International Conference on Signal Processing and Advance Research in Computing*, 2024.
- [18] X. Li, X. Fang, G. Yang, S. Su, L. Zhu, and Z. Yu, "TransU<sup>2</sup>-Net: an effective medical image segmentation framework based on transformer and U<sup>2</sup>-Net," *IEEE Journal of Translational Engineering in Health and Medicine*, vol. 11, pp. 441–450, 2023.
- [19] A. Kumar, O. Murthy, Shrish, P. Ghosal, A. Mukherjee and D. Nandi, "A dense U-Net architecture for multiple sclerosis lesion segmentation," in *IEEE Region 10 Conference*, 2019.
- [20] S. Aslani, M. Dayan, L. Storreli, M. Filippi, V. Murino and M. Rocca, "Multi-branch convolutional neural network for multiple sclerosis lesion segmentation," *NeuroImage*, vol. 196, pp. 1–15, 2019.



- [21] M. E. Salem, S. Valverde and M. Cabezas, "Multiple sclerosis lesion synthesis in MRI using an encoder-decoder U-Net," *IEEE Access*, vol. 7, pp. 25171–25184, 2019.
- [22] A. Alijamaat, A. NikravanShalmani, and P. Bayat, "Multiple sclerosis lesion segmentation from brain MRI using U-Net based on wavelet pooling," *International Journal of Computer Assisted Radiology and Surgery*, 2021.
- [23] P. Ashtari, B. Barile, S. Van Huffel, and D. Sappéy-Marinié, "New multiple sclerosis lesion segmentation and detection using pre-activation U-Net," *Frontiers in Neuroscience*, vol. 16, 2022.
- [24] Z. Zhang, Q. Liu, and Y. Wang, "Road extraction by deep residual U-Net," *IEEE Geoscience and Remote Sensing Letters*, vol. 15, no. 5, pp. 749–753, 2018.
- [25] J. Colman, L. Zhang, W. Duan, and X. Ye, "DR-Unet104 for multimodal MRI brain tumor segmentation," *Lecture Notes in Computer Science*, pp. 410–419, 2021.
- [26] B. Sarica and D. Z. Seker, "New MS lesion segmentation with deep residual attention gate U-Net utilizing 2D slices of 3D MR images," *Frontiers in Neuroscience*, vol. 16, 2022.
- [27] B. Sarica, D. Z. Seker, and B. Bayram, "A dense residual U-net for multiple sclerosis lesions segmentation from multi-sequence 3D MR images," *International Journal of Medical Informatics*, vol. 170, p. 104965, 2023.
- [28] M. Rajasekar, A. Mukil, and R. Lakshamanan, "Segmentation and evaluation of multiple sclerosis in flair modality MRI with ResUNet," *AIP conference proceedings*, vol. 3161, 2024.
- [29] V. Ganepola, P. Mathur, O. Adegboro, J. Dietmeier and A. Lawlor "XAI-ResUNet: analysing the impact of pre-training in ResUNet architectures for multiple sclerosis lesion segmentation using EigenGradCAM," *IET Conference Proceedings*, no. 10, pp. 299–302, 2024
- [30] O. Oktay, J. Schlemper, L. Folgoc, and M. Lee, "Attention U-Net: learning where to look for the pancreas," in *1st Conference on Medical Imaging with Deep Learning*, 2018.
- [31] C. hu, G. Kang, B. Hou, Y. Ma, F. Labeau and Z. Su, "ACU-NET: a 3D attention context U-Net for multiple sclerosis lesion segmentation," in *IEEE International Conference on Acoustics, Speech and Signal Processing*, 2020.
- [32] M. Hashemi, M. Akhbari, and C. Jutten, "Delve into multiple sclerosis (MS) lesion exploration: A modified attention U-Net for MS lesion segmentation in brain MRI," *Computers in Biology and Medicine*, vol. 145, 2022.
- [33] A. Rondinella, E. Crispino and F. Guarnera, "Boosting multiple sclerosis lesion segmentation through attention mechanism," *Computers in Biology and Medicine*, vol. 161, pp. 107021–107021, 2023.
- [34] P. Ghosal, A. Roy and R. Agarwal, "Compound attention embedded dual channel encoder-decoder for ms lesion segmentation from brain MRI," *Multimedia Tools and Applications*, pp.1-33, 2024.

## Segmentation Methods for MS Lesions in MRI Images Using U-Net-Based Architectures

Fariba Namiranian<sup>1</sup>, AliMohammad Latif<sup>2\*</sup>, Mahdi Yazdian-Dehkordi<sup>3</sup>, Abolfazl Nickfarjam<sup>4</sup>

<sup>1</sup>PhD Student, Computer Engineering Department, Yazd University, Yazd

<sup>2</sup>Professor, Computer Engineering Department, Yazd University, Yazd

<sup>3</sup>Associate Professor, Computer Engineering Department, Yazd University, Yazd, Iran

<sup>4</sup>Associate Professor, Shahid Sadoughi University of Medical Sciences, Yazd, Iran

### Article Information

#### Original Research Paper

#### Received:

2025 May 7

#### Accepted:

2025 June 22

#### Keywords:

Image Segmentation, Multiple Sclerosis, Brain Plaque Detection, Attention Module, Deep Learning

#### Corresponding Author\*:

alatif@yazd.ac.ir

### Abstract

MS is one of the most common autoimmune disorders of the central nervous system. It is characterized by the destruction of the myelin sheath of nerve cells and the formation of lesions in brain and spinal cord tissues. Accurate detection of lesions in MRI images plays a crucial role in diagnosing the disease, predicting patient recovery, and selecting appropriate treatment methods. In this article, with a review and analytical approach, the performance of three widely used deep learning architectures including U-Net, ResUNet, and AttentionUNet in the segmentation of MS lesions is examined and compared. After introducing commonly used datasets and evaluation metrics in this field, results from 34 reliable studies were analyzed using the Dice coefficient. On average, U-Net, ResUNet, and AttentionUNet architectures achieved Dice scores of 0.6562, 0.6937, and 0.7435 respectively in MS lesion segmentation in the reviewed studies. The results show that AttentionUNet performs better than other methods. Also, the strengths and weaknesses of each method are analyzed and future research directions in this area are proposed.

 : 10.22034/ABMIR.2025.23082.1126

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2025.23082.1126)

/The Author 2025. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

