

# شبکه کانولوشن بهینه شده با الگوریتم فراابتکاری LO برای طبقه‌بندی خودکار تومور مغزی

موسا. mojarad@iau.ac.ir<sup>۱</sup>

m.mohebi@iau.ac.ir<sup>۲</sup>

<sup>۱</sup>گروه کامپیوتر، واحد فیروزآباد، دانشگاه آزاد اسلامی، فیروزآباد، ایران

<sup>۲</sup>گروه کامپیوتر، واحد فیروزآباد، دانشگاه آزاد اسلامی، فیروزآباد، ایران

**چکیده:** بدون شک، مغز به‌عنوان حساس‌ترین عضو بدن، عملکردهای اساسی و مهم بدن انسان را کنترل می‌کند. تومور مغزی یک بیماری سرطانی شدید است که به دلیل تقسیم غیرقابل کنترل و غیرطبیعی سلول‌ها ایجاد می‌شود. به دلیل اینکه طبقه‌بندی نادرست تومور مغزی می‌تواند به عواقب بدی منجر شود، انتخاب درست نوع و درجه تومور نقش مهمی در تعیین برنامه درمانی مناسب دارد. به همین دلیل، طبقه‌بندی خودکار تومور مغزی نقش حیاتی و کارآمدی در شستاب دادن به فرایند درمان، برنامه‌ریزی و افزایش نرخ بقای بیماران دارد. به‌منظور پرداختن به این مسئله، رویکرد جدیدی به نام شبکه کانولوشن بهینه شده با الگوریتم فراابتکاری (LO CNN) توسعه داده شده است. این رویکرد شامل پیش‌پردازش تصاویر MRI مغز برای کاهش نرخ تشخیص کاذب تومور است. سپس، با استفاده از بخش‌های خطی برای حفظ جزئیات لبه‌های پنهان، یک فرایند ناحیه‌کاندید برای شناسایی ناحیه تومور اعمال می‌شود. ویژگی‌های مختلفی از ناحیه تقسیم‌بندی شده استخراج می‌شود که با استفاده از یک شبکه عصبی کانولوشنال (CNN) طبقه‌بندی می‌شود. سیستم LO CNN پیشنهادی با استفاده از معیارهای دقت پیکسل، نرخ خطا، دقت، ویژگی و حساسیت ارزیابی شده است. این سیستم با دقت ۹۹٪ بر روی مجموعه داده‌های Kaggle به دست می‌آید.

**کلید واژه‌ها:** الگوریتم فراابتکاری LO، کاهش از دست دادن لبه تصویر، شبکه عصبی کانولوشنال، تومور مغزی.

## ۱. مقدمه

مغز حساس‌ترین عضو بدن است که عملکردهای اصلی بدن را کنترل می‌کند [۱]. تومور مغزی (BT) یک بیماری سرطانی شدید است که در اثر تقسیم غیرقابل کنترل سلول‌ها ایجاد می‌شود [۲]. شناسایی صحیح نوع و درجه تومور برای انتخاب برنامه درمانی دقیق ضروری است [۳]. امروزه پردازش تصاویر پزشکی، هوش مصنوعی (AI) و یادگیری عمیق (DLA) نقش مهمی در تشخیص و طبقه‌بندی BT دارند. در سال‌های اخیر، با کمک AI و DLA، پیشرفت‌های زیادی در تکنیک‌های IP صورت گرفته است. استفاده از CNN یکی از امیدوارکننده‌ترین روش‌های DLA جهت مقابله با چندین کار تشخیص الگو است. با این حال، مانند بسیاری از شبکه‌های عصبی مصنوعی، CNNها مستعد چندین بهینه محلی هستند [۵]. CNNها به‌طور گسترده در بحث طبقه‌بندی تصاویر استفاده می‌شوند و عملکرد قابل توجهی داشته‌اند. انتخاب معماری و تنظیمات مولفه‌های CNN، هم بر سرعت همگرایی و هم بر دقت آن تأثیر زیادی دارد. طراحی و بهینه‌سازی یک معماری جدید CNN به تخصص زیادی نیاز دارد و می‌تواند بسیار وقت‌گیر باشد [۴]. ConvNet کاربردهای گسترده‌ای در تجزیه و تحلیل کلان داده و بینایی کامپیوتر دارد [۵]، اما به منابع محاسباتی زیادی نیاز دارد. دلایل اصلی محدودیت ConvNet در حل مشکلات به سبب نیازهای حافظه، محاسبات بالا و وابستگی به داده‌ها است. مدل‌های ConvNet عملکرد بهتری از روش‌های معیار در IP دارند [۶]، اما آموزش آنها بدون نیاز به حافظه و محاسبات بالا و وابستگی به داده‌ها هنوز یک مسئله باز است. همچنین باید بهینه‌سازی محاسبات و سرعت آن را علاوه بر کارایی در پردازش در هنگام طراحی معماری ConvNet در نظر داشت. در این تحقیق جهت حل این مشکلات از CNN و الگوریتم فراابتکاری LO استفاده خواهد شد. برای بهبود نرخ تشخیص تومور، تصاویر

تشدید مغناطیسی مغز (MR) از قبل پردازش شده و پیکسل‌های نویز حذف می‌شوند. در مراحل بعد، فرایند ناحیه منتخب جهت شناسایی ناحیه تومور اعمال خواهد شد. روش منطقه کاندید، به منظور کاهش از دست دادن جزئیات لبه پنهان، با کمک مفهوم قطعات خط، مناطق مرزی را بررسی خواهد کرد.

## ۲. تومورهای مغزی (BTs)

مغز انسان، به عنوان مرکز فرماندهی سیستم عصبی، مسئول فعالیت‌های روزانه است و محرک‌ها را از اندام‌های حسی دریافت و پردازش می‌کند و سیگنال‌های خروجی را به ماهیچه‌ها می‌فرستد [۷]. تومورهای مغزی (BT) یکی از شدیدترین شرایط مربوط به مغز هستند که در آن سلول‌های غیرطبیعی به طور غیرقابل کنترل رشد می‌کنند [۸]. BTها به دو نوع متاستاتیک اولیه و ثانویه طبقه‌بندی می‌شوند؛ نوع اولیه غیرسرطانی است و از سلول‌های مغزی منشا می‌گیرد، در حالی که نوع ثانویه از طریق جریان خون به مغز گسترش می‌یابد [۹]. سازمان بهداشت جهانی (WHO) BTها را بر اساس بدخیمی به چهار دسته طبقه‌بندی می‌کند و تشخیص زودهنگام و طبقه‌بندی آن‌ها برای برنامه‌ریزی درمانی مناسب ضروری است [۱۰]. تصویربرداری رزونانس مغناطیسی (MRI) و توموگرافی کامپیوتری (CT) معمولاً برای تشخیص و تجزیه و تحلیل BTها استفاده می‌شود [۱۱]. سه نوع اصلی BT اولیه شامل گلیوما، هیپوفیز و مننژیوم است و تقسیم‌بندی دقیق تومور برای راهنمایی رادیولوژیست‌ها در شناسایی بهتر تومورها حیاتی است [۱۲]. پردازش تصویر پزشکی در تجزیه و تحلیل BT، مانند طبقه‌بندی، تقسیم‌بندی و تشخیص استفاده می‌شود و سیستم‌های تشخیصی به کمک رایانه در این زمینه به رادیولوژیست‌ها کمک می‌کنند [۱۳]. یادگیری ماشینی (ML) و یادگیری عمیق (DL) دو تکنیک اصلی برای تشخیص BT هستند. روش‌های مختلف ML، مانند ماشین‌های بردار پشتیبان (SVM) و شبکه‌های عصبی مصنوعی (ANN)، برای تشخیص BT پیشنهاد شده‌اند [۱۴]. اما این روش‌ها بر ویژگی‌های دست‌ساز متکی هستند و دقت تشخیص و طبقه‌بندی به کیفیت ویژگی‌های استخراج شده بستگی دارد [۱۵]. همچنین، طبقه‌بندی‌کننده‌های ML زمان‌بر هستند و برای مجموعه داده‌های بزرگ به حافظه زیادی نیاز دارند [۱۶]. از سوی دیگر، روش‌های DL، به ویژه شبکه‌های عصبی کانولوشن (CNN)، به دلیل توانایی در استخراج خودکار ویژگی‌ها از مجموعه داده‌های بزرگ که منجر به افزایش دقت می‌شود، برای تشخیص و طبقه‌بندی BT استفاده می‌شوند [۱۷]. چندین معماری یادگیری عمیق مانند DenseNet، ResNet و InceptionNet برای تقسیم‌بندی BT پیشنهاد شده است [۱۸]. BTها بیماری‌های خطرناکی هستند و تومورهای درجه بالا می‌توانند به طور قابل توجهی زندگی بیمار را کاهش دهند، بنابراین تشخیص زودهنگام و طبقه‌بندی دقیق برای درمان موثر و بهبود کیفیت زندگی بیمار بسیار مهم است [۱۹].

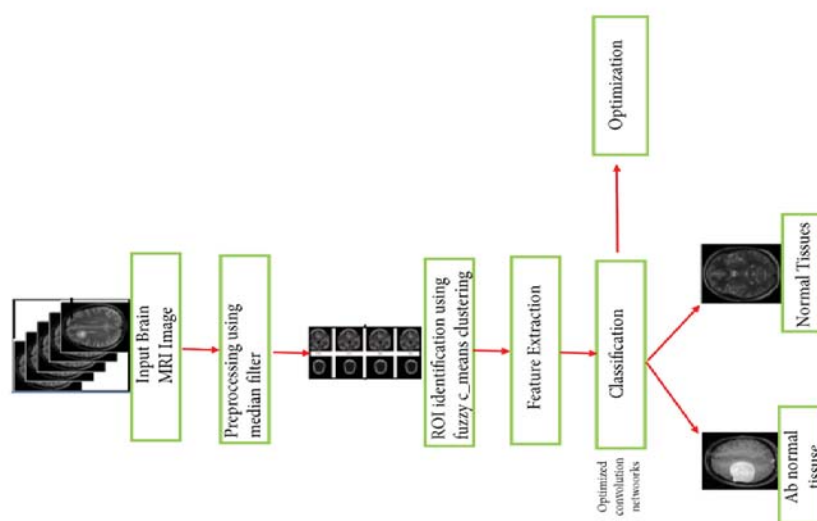
## ۳. کارهای گذشته

در [۲۰]، یک بررسی در زمینه تحلیل تصاویر پزشکی مبتنی بر MRI جهت تشخیص و طبقه‌بندی تومورهای مغزی (BT) انجام شده است. در این بررسی، مقالات مربوط به شناسایی و ارزیابی خطر سطح تومور در تصاویر MRI مورد تحلیل قرار گرفته‌اند. در [۲۱]، الگوریتمی برای تشخیص BT با استفاده از انتخاب ویژگی بهینه و بهینه‌سازی شبکه باور عمیق ارائه شده است. در این روش، بهینه‌سازی شبکه باور عمیق با استفاده از الگوریتم جستجوی ممنوعه و بهینه‌سازی ویژگی با استفاده از الگوریتم ژنتیک (GA) انجام شده است. در [۲۲]، برای تجزیه و تحلیل BT از روش‌های یادگیری عمیق (DLA) و بهینه‌سازی شده شبکه -۱۶VGG استفاده شده است. در این روش، از انواع مختلفی از شبکه‌های عمیق و الگوریتم‌های پیشرفته برای تحلیل دقیق و اصولی تصاویر تومور استفاده شده است. در [۲۳]، از الگوریتم‌های فراابتکاری برای تشخیص و پیش‌بینی BT استفاده شده است. در این روش، ابتدا ویژگی‌های مربوط به BT استخراج و سپس با استفاده از الگوریتم‌های فراابتکاری، شبکه‌های عصبی مختلفی آموزش داده شده‌اند تا دقت پیش‌بینی و تشخیص BT بهبود یابد. در [۲۴]، تصاویر BT برای آموزش شبکه‌های عصبی کانولوشن (CNN) ترکیب شده‌اند. در این روش، از دو لایه کانولوشن، دو لایه max-pooling، و در نهایت از دو لایه جهت فرایند طبقه‌بندی نهایی استفاده شده است.

## ۴. روش پیشنهادی

روش پیشنهادی شامل چندین مرحله است: جمع‌آوری تصویر، کاهش نویز تصویر، تقسیم‌بندی و خوشه‌بندی تصویر، انتخاب و استخراج ویژگی، و طبقه‌بندی. شکل ۱ فرایند طبقه‌بندی تومور مغزی (BT) را از تصاویر MRI با استفاده از شبکه عصبی کانولوشن بهینه‌سازی شده هریس هاکس (HHOCNN) نشان می‌دهد.


شناسایی حجم ناخالص تومور یک گام مهم در آماده‌سازی برای درمان رادیوتراپی است، زیرا اساس طراحی و تحویل درمان را تشکیل می‌دهد. اگر حاشیه‌های ایمنی اعمال شده برای جبران خطاها در تعیین تومور کافی نباشد، ممکن است منجر به اشتباهات جغرافیایی سیستماتیک در طول درمان شود و احتمال کنترل تومور کاهش یابد. تعریف ناکافی هدف سه‌بعدی ممکن است از استفاده کامل از تکنیک‌های برنامه‌ریزی درمانی پیشرفته جلوگیری کند که می‌تواند منجر به از دست دادن کنترل تومور به دلیل از دست دادن دوز جغرافیایی شود. هدف این پژوهش بهبود دقت تشخیص تومور و کاهش خطاهای طبقه‌بندی نادرست با استفاده از یک تکنیک تقسیم‌بندی مؤثر برای شناسایی منطقه مورد نظر و استخراج ویژگی‌های مرتبط با تومور است. شکل ۱ روند کار با جزئیات روش معرفی BT را نشان می‌دهد.



شکل ۱. فلوچارت پیشنهادی طبقه‌بندی تومور مغزی

#### ۴-۱. مجموعه داده

در این مقاله، از مجموعه داده Kaggle Brain MRI برای تشخیص تومور مغزی (BT) استفاده شده است. این مجموعه شامل ۲۵۳ تصویر مغزی است که شامل موارد سرطانی و غیرسرطانی می‌باشد. شکل ۲ نمونه‌ای از تصویر MRI از این مجموعه داده را نشان می‌دهد.



شکل ۲. نمونه‌های MRI شامل: تصاویر MRI طبیعی مغز با لیبل Y1 تا Y8، تصاویر MRI تومور خوش خیم با لیبل Y9 تا Y15 و تصاویر MRI تومور بدخیم با لیبل Y16 تا Y21.

مجموعه داده در دو پوشه سازماندهی شده است؛ پوشه‌ای با عنوان "بدون تومور" که با ۰ و پوشه‌ای با عنوان "تومور" که با ۱ نمایش داده می‌شود. داده‌های برچسب‌گذاری شده برای استخراج الگو از MRI مفید هستند که به پیش‌بینی خروجی برای تصاویر جدید کمک می‌کند. با این حال، تصاویر جمع‌آوری شده تحت تأثیر نویز قرار می‌گیرند که می‌تواند بر دقت تشخیص BT تأثیر منفی بگذارد. برای افزایش راندمان پیش‌بینی کلی، نویز در تصاویر با استفاده از تکنیک کاهش نویز تصویر حذف می‌شود. این فرایند بهبود تصاویر اولیه و ایجاد داده‌های ورودی با کیفیت بالا برای مراحل بعدی تحلیل و طبقه‌بندی را تضمین می‌کند.

#### ۴-۲. مرحله پیش‌پردازش

مرحله اولیه بر حذف نویز از تصاویر MRI مغز متمرکز است تا از اختلال در شناسایی ناحیه تومور جلوگیری شود. سپس، تصاویر برای بهینه‌سازی کیفیت MRI بر اساس کنتراست و اطلاعات پیکسل تجزیه و تحلیل می‌شوند. این شامل شناسایی و حذف سریع اطلاعات سطح پایین و بررسی شدت پیکسل‌ها برای بهبود کیفیت تصویر است. برای این کار، از فیلتر میانه و یکسان‌سازی هیستوگرام استفاده می‌شود. تصاویر به زیر تصاویر تقسیم شده، هر پیکسل با مقدار آستانه مقایسه می‌شود و پیکسل‌های نویزی با مقدار متوسط جایگزین می‌شوند. در نهایت، کنتراست تصویر با یکسان‌سازی هیستوگرام بهبود می‌یابد.

$$\begin{aligned} f(j, i) & \quad (1) \\ &= \text{Median}\{g(o, t), (o, t) \\ &\in S_{ji}\} \end{aligned}$$

نویز موجود در تصویر با  $g(o, t)$  نشان داده می‌شود و تکنیک فیلتر میانه شامل مرتب‌سازی پیکسل‌ها در یک پنجره فیلتر کشویی است. مقدار پیکسل خروجی  $f(j, i)$  با گرفتن میانه مقادیر پیکسل مرتب‌شده به دست می‌آید. مجموعه داده شامل نمونه‌های  $S$  با اطلاعات پیکسلی در سطح خاکستری  $Gr$  است که با  $P0, P1$  نشان داده می‌شوند. برای هر پیکسل، شدت و مقدار توزیع تجمعی برای ارزیابی کیفیت پیکسل محاسبه می‌شود. سپس کیفیت پیکسل بر اساس تابع چگالی مشخص شده به صورت زیر تعیین می‌گردد.

$$PDF(Pn) = \frac{n^h}{n} \quad (2)$$

مقدار پیکسل تصویر مغز به صورت  $n^h$  نشان داده می‌شود که در آن  $h$  از ۰ تا  $Gr-1$  می‌باشد و  $n$  تعداد کل پیکسل‌های مجموعه داده است. توزیع تجمعی پیکسل با محاسبه میانگین وزنی مقدار پیکسل با استفاده از رابطه زیر تعیین می‌شود.

$$x_t = \frac{\sum_{lg}^b = a^l * CDF(lg)}{\sum_{lg}^b = a^l CDF(lg)} \quad (3)$$

مقدار پیکسل خاکستری یک تصویر به صورت  $g$  نشان داده می‌شود. مقدار هیستوگرام زیر بازه به صورت  $(a, b)$  تعریف می‌شود که معمولاً در محدوده  $0$  تا  $255$  قرار می‌گیرد. مقدار بازه  $t$  است که  $0 \leq r \leq t-1$  و  $r$  نشان دهنده زیر هیستوگرام  $(X_r)$  می‌باشد. هنگامی که فاصله فرعی تعریف شد، تصاویر فرعی برای محاسبه هیستوگرام تصویر شناسایی می‌شوند.

$$S_K = \{S(x, y) | X_k\} \leq S(x, y)X_{k+1}, \forall S(x, y) \in S \quad (4)$$


تصاویر فرعی مجموعه داده  $S$  به صورت  $S_k$  نشان داده می‌شوند که  $k$  از  $0$  تا  $t-1$  متغیر می‌باشد. سپس احتمال و توزیع تجمعی تصاویر در سطح خاکستری به صورت زیر محاسبه می‌شود:

$$PDF_k(P_h) = \frac{n^k}{n_k} \quad (5)$$

$$CDF(Gr_j) = \sum_{j=X_0+1}^n PDF_k(Gr_j) \quad (6)$$

برای هر تصویر فرعی  $S_k$  (که در آن  $k$  از  $0$  تا  $t-1$  متغیر می‌باشد) و  $h = X_{k+1}, \dots, X_{k+2}, \dots, X_{k+1}$  توزیع احتمال پیکسل‌ها به صورت  $PDF_k(P_h)$  نشان داده می‌شود. که با استفاده از تمام پیکسل‌های تصویر محاسبه می‌شود.

جدول ۱. نمونه پیش پردازش شده



تصویر پیش پردازش شده  
تصویر MRI

هیستوگرام  
تصویر

کنتراست تصاویر  
بهبود یافته

## ۳-۴. مرحله قطعه‌بندی


مرحله بعدی شناسایی ناحیه تومور از تصاویر MRI از پیش‌پردازش شده است. تشخیص BT اغلب تحت‌تأثیر جزئیات مرزی نامشخص و نامشخص در MRI قرار می‌گیرد که می‌تواند منجر به پیچیدگی محاسبات و تقسیم‌بندی نادرست شود. برای پرداختن به این مسائل، این مقاله از رویکرد خوشه‌بندی c-means فازی (FCM) استفاده می‌کند. FCM از مجموعه‌های فازی و مقادیر عضویت برای به حداقل رساندن عدم قطعیت استفاده می‌کند. در ابتدا، درجه ارزش عضویت برای حل مشکل عدم قطعیت اعمال می‌شود، زیرا به شناسایی رابطه بین هر پیکسل کمک می‌کند. سپس از روابط پیکسلی محاسبه شده برای تعیین مقدار مرکز خوشه استفاده می‌شود که با معادله (7) تعریف می‌شود.

$$V_j = \frac{(\sum_{i=1}^n (\mu_{ij})^m x_i)}{(\sum_{i=1}^n (\mu_{ij})^m)}, \forall j = 1, 2, \dots, c \quad (7)$$

در این توصیف،  $n$  تعداد پیکسل‌های تصویر و  $V_j$  برای نشان دادن مرکز خوشه  $j$  ام استفاده می‌شود. مقدار شاخص فازی با استفاده از مقدار  $m$  نشان داده می‌شود که می‌تواند از ۱ تا بی‌نهایت باشد. تعداد مراکز خوشه با  $c$  مشخص می‌شود و مقدار عضویت فازی برای هر پیکسل  $i$  و مرکز خوشه  $j$  با  $\mu_{ij}$  نشان داده می‌شود. مقدار عضویت فازی  $s$  از فاصله اقلیدسی  $d_{ij}$  بین  $i$  امین پیکسل و  $j$  امین مرکز خوشه محاسبه می‌شود. سپس مقادیر عضویت فازی برای هر پیکسل و مرکز خوشه محاسبه می‌شود.

$$\mu_{ij} = \frac{1}{\sum_{k=1}^c (d_{ij}/d_{ik})^{2/m-1}} \quad (8)$$

برای شناسایی ناحیه مبتلا به تومور، مقادیر هر نقطه داده  $X = (x_1, x_2, \dots, x_n)$  باید تجزیه و تحلیل شود و مجموعه مراکز  $V = (v_1, v_2, \dots, v_c)$  برابر می‌باشد. محاسبه شده است. منطقه کاندید برای بررسی منطقه مرزی بخش خط بررسی می‌شود که از دست دادن جزئیات لبه پنهان را کاهش می‌دهد. منطقه کاندید به‌عنوان یک دایره بالقوه درگیر نشان داده می‌شود و یکی با بیشترین بخش‌های خط انتخاب می‌شود. منطقه بهینه، ناحیه‌ای است که دایره بهینه را در خود دارد. منطقه کاندید با انتخاب نقاط بذریه بر اساس تجزیه و تحلیل پیکسلی شناسایی می‌شود. محاسبه دقیق اطلاعات پیکسلی به حفظ اطلاعات لبه کمک می‌کند و پیچیدگی مرتبط با پردازش جزئیات داخلی را کاهش می‌دهد. با توجه به این بحث، مناطق تقسیم شده در جدول نشان داده شده است.



تصویر پیشرفته      تصویر تشخیص لبه      تصویر قطعه‌بندی شده

شکل ۳. نمونه تصاویر بخش‌بندی شده ناحیه تومور مغز


شکل ۳ ناحیه تقسیم شده و ناحیه مربوط به لبه را نشان می‌دهد. استخراج ویژگی بر روی مناطق تقسیم شده انجام می‌شود تا اطلاعات مختلفی از تصاویر MRI به دست آید. استفاده موثر از نقاط بذر به شناسایی موفقیت آمیز منطقه کاندید کمک می‌کند و در نتیجه دقت کلی تشخیص تومور را بهبود می‌بخشد.

#### ۴-۴. مرحله استخراج ویژگی

استخراج ویژگی‌ها بر اساس استدلال تقریبی از روش‌های مهمی است که در تشخیص شکل و محل تومورها در تصاویر MRI مورد استفاده قرار می‌گیرد. این روش‌ها بر اساس تشخیص لبه‌ها و ویژگی‌های بافتی متمرکز هستند که از طریق تحلیل آماری توزیع فضایی سطوح خاکستری در تصاویر به دست می‌آیند.

#### ۴-۵. مرحله طبقه‌بندی تومور

مرحله نهایی شامل طبقه‌بندی BT با استفاده از یک CNN بهینه‌سازی شده فراابتکاری می‌باشد. مدل CNN شامل ورودی، کانولوشن، واحد خطی اصلاح‌شده، ادغام و لایه‌های کاملاً متصل می‌باشد. این لایه‌ها برای تجزیه و تحلیل مناطق کوچک در یک تصویر قطعه‌بندی شده مفید هستند. تصاویر ابتدا توسط یک لایه کانولوشن پردازش می‌شوند که آنها را به مناطق کوچک‌تر تجزیه می‌کند. سپس فرایند ReLU از یک تابع فعال‌سازی از نظر عنصر استفاده می‌کند و برای کاهش ابعاد مجموعه ویژگی‌ها، ادغام اعمال می‌شود. در نهایت، خروجی در لایه کاملاً متصل به دست می‌آید که برچسب‌های ۱ و ۰ را به ورودی اختصاص می‌دهد.



شکل ۴. بهترین معماری CNN برای مجموعه داده

تصاویر جمع آوری شده به مراحل آموزشی و آزمایشی تقسیم می‌شوند. در مرحله آموزش، از مراحل فوق برای تولید الگوهای خروجی استفاده می‌شود که انحرافات تابع ضرر را به حداقل می‌رساند. پیچیدگی محاسبات، یعنی زمان و هزینه، با استفاده از مدل قبل از آموزش به حداقل می‌رسد. در طول آموزش، تصاویر به صورت خودکار اطلاعات را با استفاده از لایه‌های مختلف استخراج می‌کنند و خروجی‌های به دست آمده در پایگاه داده ذخیره می‌شوند. سپس، تصاویر آزمایشی با الگوهای آموزش دیده مطابقت داده می‌شوند تا عملکرد تلفات کاهش یابد. الگوریتم نزول گرادیان برای اندازه‌گیری تابع تلفات استفاده می‌شود. اگر سیستم انحرافات زیاد را نشان می‌دهد، پارامترهای شبکه باید به روز شوند و یادگیری باید منتشر شود. در این مقاله از الگوریتم بهینه‌سازی Lemurs برای تنظیم پارامترهای شبکه استفاده شده است. الگوریتم بهینه‌سازی در کاهش پیچیدگی محاسبات و کاهش انحراف بین مقادیر واقعی و پیش‌بینی شده موفق است. علاوه بر این، به حداقل رساندن پیچیدگی طبقه‌بندی منجر به بهبود دقت تشخیص کلی می‌شود.

جدول ۲. پارامترهای کنترل الگوریتم بهینه ساز LO

مقدار	پارامتر
1000	بیشترین تکرار
0.5	پارامتر تصادفی
20	اندازه جمعیت

قبل از به‌روزرسانی پارامترهای شبکه، مقدار میانگین مربعات خطا (MSE) باید با استفاده از رابطه زیر محاسبه شود.

$$MSE_{error} = \frac{1}{g} \sum_{e=1}^g [Fg - Fg^*]^2 \quad (9)$$

نرخ خطای انحراف MSEerror برای اندازه‌گیری اختلاف بین خروجی‌های  $Fg$  پیش‌بینی شده و مورد انتظار استفاده می‌شود. این انحراف برای چندین نمونه محاسبه می‌شود، جایی که  $g$  نشان‌دهنده عدد نمونه می‌باشد، با  $1 \leq e \leq g$



اگر شبکه یک نرخ خطا تولید کند، پارامترهای شبکه باید بر اساس راه‌حل جهانی بهینه به‌روز شوند. برای تنظیم دقیق عملیات شبکه، الگوریتم بهینه‌سازی به حداقل پارامتر نیاز دارد. راه‌حل به‌روزرسانی، پارامترهای شبکه را بر اساس معادله زیر تنظیم دقیق می‌کند. مسئله بهینه‌سازی شامل به‌روزرسانی معادله زیر می‌باشد که در آن بردارهای ضریب با B نشان داده می‌شوند.

$$A(b + 1) = A_{rand} + BC \quad (10)$$

#### ۴-۶. تجزیه و تحلیل داده‌ها

این بخش ارزیابی عملکرد شبکه‌های عصبی کانولوشن بهینه‌سازی شده برای تشخیص تومورهای مغزی از تصاویر MRI را بررسی می‌کند. مجموعه داده برای این مطالعه از مجموعه داده‌های Brain Tumor Kaggle تشکیل شده است که شامل ۲۵۰ تصویر MRI مغز است که به دو دسته "بله" (حاوی تومور) و "خیر" (بدون تومور) تقسیم شده‌اند. استفاده از داده‌های برجسب‌گذاری شده برای آموزش و ارزیابی سیستم بهبود دقت طبقه‌بندی تصاویر آزمایشی را تضمین می‌کند.

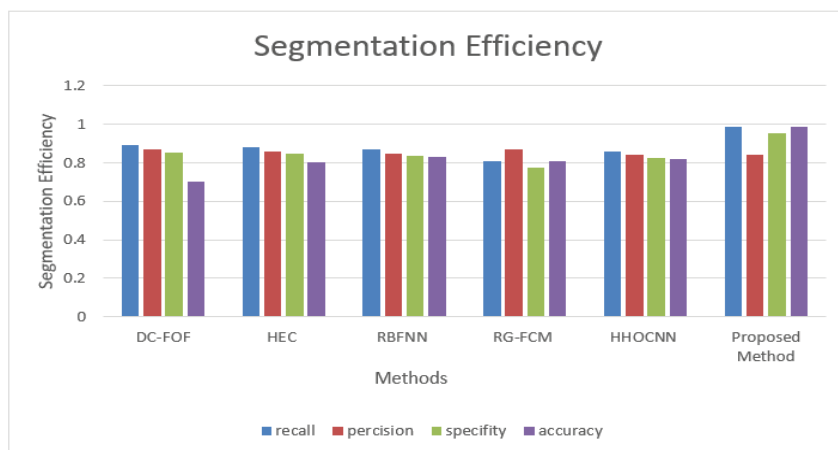
سیستم پیاده‌سازی شده با استفاده از ابزار MATLAB انجام شده است و از تکنیک‌های پردازش تصویر و یادگیری ماشینی برای تشخیص تومور استفاده می‌کند. در این سیستم، از فیلتر میانه وزنی برای حذف نویز از تصاویر MRI استفاده می‌شود که بهبود محاسبات و تقسیم‌بندی منطقه را فراهم می‌آورد. در مرحله شناسایی، نقاط بذر مبتنی بر عضویت فازی برای شناسایی مناطق کاندید استفاده می‌شود که به دقت تشخیص تومور کمک می‌کند. این روش به تحلیل دقیق مناطق و بهبود کلی دقت تشخیص کمک می‌کند. برای ارزیابی عملکرد سیستم، معیارهای سنتی مانند دقت، حساسیت، ویژگی، دقت و امتیاز F1 برای ارزیابی کارایی به کار می‌رود. نتایج ارزیابی بر اساس این معیارها به صورت جدولی در جدول ۳ نمایش داده شده است. در این جدول، عملکرد شبکه‌های عصبی کانولوشن بهینه‌سازی شده با استفاده از الگوریتم فراابتکاری LO با سایر روش‌های مقایسه شده است، از جمله شبکه‌های RBFNN، MENF و الگوریتم HHOCNN.

جدول ۳. کارایی تقسیم‌بندی تومور مغزی

روش‌ها	دقت	Precision	دقت	Recal	امتیاز F1
HHOCNN [25]	۰,۹۸	۰,۹۸۳	۰,۹۷۹	۰,۹۸۷	۰,۹۸۸
[26] DC-FOF	۰,۸۵۶	۰,۸۳۴	۰,۸۶	۰,۸۹۳	۰,۸۹۲
HEC [27]	۰,۸۹	۰,۸۹۳	۰,۹۰۲	۰,۹۳	۰,۹۳۲
RBFNN [28]	۰,۹۰۲	۰,۹۰۲	۰,۹۱	۰,۹۴۵	۰,۹۵
RG-FCM [29]	۰,۹۲۳	۰,۹۱	۰,۹۲۳	۰,۹۵۴	۰,۹۶۷
روش پیشنهادی	0.99	5۰,۹۸	0.98	0.99	0.989

در این ارزیابی، از ماتریس سردرگمی برای مقایسه عملکرد روش‌ها با معیارهایی مانند دقت، حساسیت، دقت، بازخوانی و  $F1$ -score استفاده شده است. همچنین، منحنی ROC برای ارزیابی عملکرد کلی یک تست تشخیصی و مقایسه آن با سایر تست‌های تشخیصی به کار رفته است. این منحنی به انتخاب مقادیر برش بهینه برای شناسایی وجود یا عدم وجود BT کمک می‌کند. شکل ۵ نشان می‌دهد که روش RG-FCM با استفاده از خوشه‌بندی C-means فازی توانسته است تقسیم‌بندی مغز را با دقت بالا به طور مؤثر انجام دهد. این روش با استفاده از توابع عضویت فازی، مرکز دقیق خوشه‌ها را تعیین کرده و مشکلات عدم قطعیت را در بررسی مناطق پیکسل کاهش می‌دهد. همچنین، CNN شامل لایه‌های مختلفی است که منطقه را در مدل پیش‌آموزشی تقسیم‌بندی می‌کند و انحراف بین

مقادیر واقعی و پیش‌بینی شده را به حداقل می‌رساند. روش RG-FCM با رویکرد پیشنهادی به دقت ۹۹٪ دست یافته است که بالاتر از سایر روش‌ها به جز چارچوب MENF است. این نتایج حاکی از عملکرد برتر روش RG-FCM در مقایسه با سایر روش‌ها است. در مطالعه ارزیابی تشخیصی تومورهای مغزی با استفاده از تصاویر MRI، روش پیشنهادی با خوشه‌بندی C-means فازی (RG-FCM) برای تشخیص دقیق‌تر تومورها از روش‌های دیگر مانند DC-FOF، HEC، RBFNN و MENF بهتر عمل کرده است. این روش از شبکه‌های عصبی کانولوشنی (CNN) برای نمونه‌برداری و پردازش تصاویر استفاده می‌کند که باعث کاهش تأثیر نویزها و بهبود دقت تشخیص تومورها می‌شود. از معیارهای ارزیابی مانند دقت، حساسیت، بازخوانی و F-score برای اندازه‌گیری عملکرد سیستم استفاده شده است. انحرافات کم بین خروجی‌های مورد انتظار و پیش‌بینی شده نشان دهنده کارایی بالای روش پیشنهادی است.



شکل ۵. کارایی تقسیم‌بندی.

جدول ۴. توابع معیار ارزیابی.

تابع	تابع تست	دامنه	$n$	$C$	$f(x^*)$
F1	$\sum_{i=1}^n x_i^2$	$x_i \in [-100,100]$	30	$U$	0
F2	$\sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	$x_i \in [-10,10]$	30	$U$	0
F3	$\sum_{i=1}^n \left( \sum_{j=1}^i -1 x_j \right)^2$	$x_i \in [-100,100]$	30	$U$	0
F4	$\max_i \{ x_i , 1 \leq i \leq n\}$	$x_i \in [-100,100]$	30	$U$	0
F5	$\sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$x_i \in [-30,30]$	30	$U$	0
F6	$\sum_{i=1}^n ([x_i + 0.5])^2$	$x_i \in [-100,100]$	30	$U$	0
F7	$\sum_{i=1}^n ix_i^4 + \text{random}[0,1)$	$x_i \in [-128,128]$	30	$U$	0

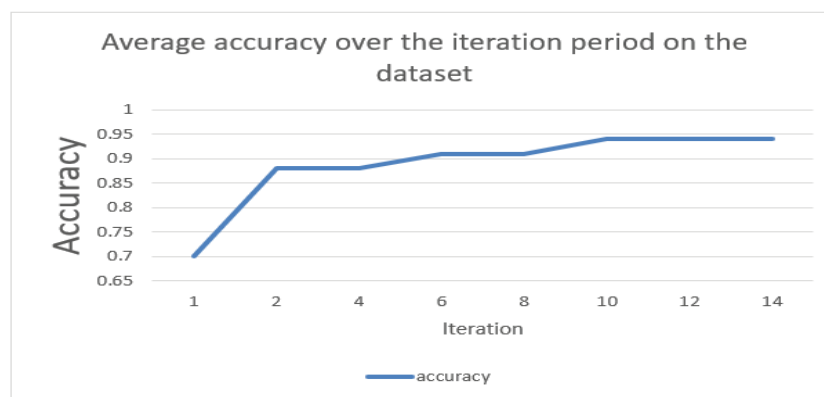


جدول ۵. عملکرد مقایسه‌ای الگوریتم LO با الگوریتم‌های ازدحام بر اساس توابع F1-F7.


تابع	LO	ABC	SSA	SCA	BA
F1	$0.0000 \times 10^0$	$2.3350 \times 10^{-16}$	$3.6020 \times 10^{-10}$	$0.0000 \times 10^0$	$5.8250 \times 10^{-6}$
F2	$0.0000 \times 10^0$	$9.5130 \times 10^{-16}$	$1.5180 \times 10^{-6}$	$0.0000 \times 10^0$	$1.0390 \times 10^{-1}$
F3	$1.3700 \times 10^{-5}$	$1.3010 \times 10^0$	$3.1910 \times 10^{-11}$	$1.9590 \times 10^{-29}$	$1.9530 \times 10^{-3}$
F5	$5.1550 \times 10^{-15}$	$1.5670 \times 10^{-2}$	$2.9060 \times 10^{-6}$	$1.3770 \times 10^{-56}$	$1.3350 \times 10^{-2}$
F5	$3.5150 \times 10^1$	$8.2800 \times 10^{-3}$	$9.1380 \times 10^0$	$2.6760 \times 10^1$	$3.0930 \times 10^{-1}$
F6	$9.7010 \times 10^{-28}$	$3.3350 \times 10^{-16}$	$2.8560 \times 10^{-11}$	$2.7520 \times 10^0$	$9.6080 \times 10^{-5}$
F7	$5.8730 \times 10^{-6}$	$2.7370 \times 10^{-2}$	$6.0950 \times 10^{-5}$	$1.9790 \times 10^{-5}$	$2.8560 \times 10^{-5}$
		FPA	JAYA	LEO-MPA	
F1		$1.930 \times 10^{-68}$	$0.0000 \times 10^0$	$0.0000 \times 10^0$	
F2		$3.2560 \times 10^{-57}$	$0.0000 \times 10^0$	$0.0000 \times 10^0$	
F3		$7.0320 \times 10^{-31}$	$6.1680 \times 10^0$	$0.0000 \times 10^0$	
F5		$6.1330 \times 10^0$	$8.5570 \times 10^{-75}$	$8.5256 \times 10^{-59}$	
F5		$1.0630 \times 10^0$	$7.1060 \times 10^{-28}$	$6.6720 \times 10^{-22}$	
F6		$1.0270 \times 10^{-33}$	$1.7170 \times 10^0$	$1.3582 \times 10^0$	
F7		$7.0020 \times 10^{-3}$	$8.0060 \times 10^{-5}$	$2.8813 \times 10^{-4}$	

جدول ۶. مقایسه روش پیشنهادی

	روش	دقت (%)
مجموعه داده	SVM + FRE [30]	52.52
	CNN + GA [31]	90.91
	CNN + mFA	93.32
	CNN + FA	92.81



شکل ۶. میانگین دقت در طول دوره تکرار بر روی مجموعه داده



شکل ۷ تجزیه و تحلیل مقایسه بر روی مجموعه داده

##### ۵. نتیجه گیری

این مقاله از یک فرایند بهینه‌سازی برای تشخیص تومورهای مغزی از تصاویر MRI استفاده می‌کند با استفاده از ترکیبی از خوشه‌بندی C-means فازی و شبکه‌های عصبی کانولوشنی (CNN) که بهینه‌سازی آن با الگوریتم فراابتکاری LO انجام می‌شود. روش پیشنهادی در این مقاله بر روی مجموعه داده Kaggle تست شده است که شامل تصاویر MRI مغزی حاوی حالت‌های طبیعی و غیرطبیعی است. مراحل پردازش تصاویر شامل استفاده از فیلتر میانه برای حذف نویز و جزئیات غیرضروری است که باعث کاهش پیچیدگی تصاویر و بهبود دقت تشخیص می‌شود. از روش فازی‌سازی نقاط برای پیش‌بینی مناطق زیر تأثیر تومور استفاده می‌شود که باعث کاهش مشکلات عدم قطعیت در تقسیم‌بندی مناطق می‌شود. شبکه‌های عصبی کانولوشنی برای استخراج ویژگی‌های مهم و تمیز از تصاویر استفاده می‌شود که توسط لایه‌های کاملاً متصل برای دقیق‌تر کردن خروجی پیش‌بینی تنظیم می‌شود. این فرایند با استفاده از الگوریتم LO بهینه‌سازی میزان

خطای طبقه‌بندی را ۰.۹۹٪ کاهش می‌دهد و دقت کلی تشخیص تومورهای مغزی را افزایش می‌دهد. نتایج نشان می‌دهند که روش پیشنهادی با دقت بالا و بهبود قابل توجهی در تشخیص تومورهای مغزی عملکرد مؤثری دارد و می‌تواند به‌عنوان یک ابزار مفید در پزشکی تصویری استفاده شود. در آینده، بهینه‌سازی بیشتر با استفاده از الگوریتم‌های فراابتکاری دیگر برای بهبود عملکرد این فرایند پیشنهاد می‌شود.

#### منابع

- Khan, H. A., Jue, W., Mushtaq, M., & Mushtaq, M. U. (2020). Brain tumor classification in MRI image [۱] using convolutional neural network. *Math. Biosci. Eng*, 17(5), 6203-6216
- Ayadi, W., Elhamzi, W., Charfi, I., & Atri, M. (2021). Deep CNN for brain tumor classification. *Neural [۲] Processing Letters*, 53, 671-700
- Murthy, M. Y. B., Koteswararao, A., & Babu, M. S. (2021). Adaptive fuzzy deformable fusion and optimized [۳] CNN with ensemble classification for automated brain tumor diagnosis. *Biomedical engineering letters*, 1-22
- Aleid, A., Alhussaini, K., Alanazi, R., Altwaimi, M., Altwijri, O., & Saad, A. S. (2023). Artificial Intelligence [۴] Approach for Early Detection of Brain Tumors Using MRI Images. *Applied Sciences*, 13(6), 3808
- Banharsakun, A. (2019). Towards improving the convolutional neural networks for deep learning using [۵] the distributed artificial bee colony method. *International journal of machine learning and cybernetics*, 10(6), 1301-1311
- Guernine, A., & Kimour, M. T. (2021). Optimized Training for Convolutional Neural Network Using [۶] Enhanced Grey Wolf Optimization Algorithm. *Informatica*, 45
- H. Yang , C. Yuan , B. Li , Y. Du , J. Xing , W. Hu , S.J. Maybank , Asymmetric 3d convolutional neural [۷] networks for action recognition, *Pattern Recognit.* 85 (2019) 1–12
- H. Baumgartl , J. Tomas , R. Buettner , M. Merkel , A novel deep-learning approach for automated non- [۸] destructive testing in quality assurance based on convolutional neural networks, in: *Proceedings of the 13th International Conference on Advanced Computational Engineering and Experimenting*, 2019
- R. Xi, M. Hou, M. Fu, H. Qu, D. Liu, Deep dilated convolution on multi- modality time series for human [۹] activity recognition, in: *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, 2018, pp. 1–8, doi: 10.1109/IJCNN.2018.8489540
- B. Oh, J. Lee, A case study on scene recognition using an ensemble convolution neural network, in: [۱۰] *Proceedings of the 20th International Conference on Advanced Communication Technology (ICACT)*, 2018, pp. 351–353, doi: 10.23919/ICACT.2018.8323752
- A. Ullah , K. Muhammad , I.U. Haq , S.W. Baik , Action recognition using optimized deep autoencoder [۱۱] and cnn for surveillance data streams of non-stationary environments, *Future Gener. Comput. Syst* (۲۰۱۹)
- Z. Wu , C. Shen , A. Van Den Hengel , Wider or deeper: revisiting the resnet model for visual recognition, [۱۲] *Pattern Recognit.* 90 (2019) 119–133
- L. Hui, S. Yu-jie, Research on face recognition algorithm based on improved convolution neural network, [۱۳] in: *Proceedings of the 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, 2018, pp. 2802–2805, doi: 10.1109/ICIEA.2018.8398186



- Z. Qin, Z. Zhang, S. Zhang, H. Yu, J. Li, Y. Peng, Merging and evolution: Improving convolutional neural networks for mobile applications, in: Proceedings of the International Joint Conference on Neural Networks (IJCNN), 2018, pp. 1–8, doi: 10.1109/IJCNN.2018.8489496
- ur Rehman, S., Tu, S., Waqas, M., Huang, Y., ur Rehman, O., Ahmad, B., & Ahmad, S. (2019). Unsupervised pre-trained filter learning approach for efficient convolution neural network. *Neurocomputing*, 365, 171-190
- Kumar, A., Singh, S., & Kumar, A. (2021, June). Grey wolf optimizer and other metaheuristic optimization techniques with image processing as their applications: a review. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1136, No. 1, p. 012053). IOP Publishing
- Kaur, S., Kumar, Y., Koul, A., & Kumar Kamboj, S. (2022). A Systematic Review on Metaheuristic Optimization Techniques for Feature Selections in Disease Diagnosis: Open Issues and Challenges. *Archives of Computational Methods in Engineering*, 1-33
- E. Ben George, "Brain Tumor Segmentation using Cuckoo Search Optimization for Magnetic Resonance Images," pp. 1–4, 2015
- M. Ramadas, "Detecting tumours by segmenting MRI images using transformed differential evolution algorithm with Kapur's thresholding," *Neural Comput. Appl.*, vol. 0, 2019, doi: 10.1007/s00521-019-04104-0
- M. P. S. Deshpande and P. S. J. Honade, "Brain Tumor Segmentation and Detection using Firefly Algorithm," vol. 12, no. 2, pp. 129–144, 2017, doi: 10.9790/2834-120203129144
- A. Halder, A. Pradhan, S. K. Dutta, and P. Bhattacharya, "Tumor extraction from MRI images using dynamic genetic algorithm based image segmentation and morphological operation," *Int. Conf. Commun. Signal Process. ICCSP 2016*, pp. 1845–1849, 2016, doi: 10.1109/ICCSP.2016.7754489
- T. Attar and T. Bhattacharjee, "Parametric Optimization of Logarithmic Transformation using GWO for Enhancement and Denoising of MRI Images
- O. Moh and R. Mandava, "A hybrid harmony search algorithm for MRI brain segmentation," pp. 31–49, 2011, doi: 10.1007/s12065-011-0048-1
- [24] Nazir, M.; Khan, M.A.; Saba, T.; Rehman, A. Brain tumor detection from MRI images using multi-level wavelets. In *Proceedings of the 2019 International Conference on Computer and Information Sciences*. New York, NY, USA, 2019; pp. 1–5:(ICCIS), Aljouf, Saudi Arabia, 3–4 April 2019; IEEE
- [25] Kurdi, S. Z., Ali, M. H., Jaber, M. M., Saba, T., Rehman, A., & Damaševičius, R. (2023). Brain Tumor Classification Using Meta-Heuristic Optimized Convolutional Neural Networks. *Journal of Personalized Medicine*, 13(2), 181.
- Nadeem, M.W.; Al Ghamdi, M.A.; Hussain, M.; Khan, M.A.; Khan, K.M.; Almotiri, S.H.; Butt, S.A. Brain Tumor Analysis Empowered with Deep Learning: A Review, Taxonomy, and Future Challenges. *Brain Sci.* 2020, 10, 118
- Melekoopappattu, J.G.; Kadan, A.B.; Anoop, V. Early detection of breast malignancy using wavelet features and optimized classifier. *Int. J. Imaging Syst. Technol.* 2021, 31, 1551–1563. [CrossRef]
- Rajinikanth, V.; Kadry, S.; Nam, Y. Convolutional-Neural-Network Assisted Segmentation and SVM Classification of Brain Tumor in Clinical MRI Slices. *Inf. Technol. Control* 2021, 50, 342–356
- Heidari, A.A.; Mirjalili, S.; Faris, H.; Aljarah, I.; Mafarja, M.; Chen, H. Harris hawks optimization: Algorithm and applications. *Futur. Gener. Comput. Syst.* 2019, 97, 849–872.
- [30] Kalbkhani, H., Shayesteh, M.G., Zali-Vargahan, B.: Robust algorithm for brain magnetic resonance image (MRI) classification based on GARCH variances series. *Biomed. Signal Process. Control* 8(6), 909 (2013). <https://doi.org/10.1016/j.bspc.2013.09.001>



- [31] Anaraki, A.K., Ayati, M., Kazemi, F.: Magnetic resonance imagingbased brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. Biocybern. Biomed. Eng. 39(1), 63 (2019). [https:// doi. org/ 10. 1016/j. bbe. 2018. 10. 004](https://doi.org/10.1016/j.bbe.2018.10.004)