

Brain Stroke Classification Based on Deep Learning Approach in Microwave Brain Imaging System

Majid Roohi¹, *PhD Student*, Jalil Mazloun², *Associate Professor*, Mohammad-Ali Pourmina¹,
Associate Professor, Behbod Ghalamkari¹, *Assistant Professor*

¹Department of Electrical and Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

²Department of Electrical Engineering, Shahid Sattari Aeronautical University of Science and Technology, Tehran, Iran

majid.roohi@srbiau.ac.ir, pourmina@srbiau.ac.ir, ghalamkari@srbiau.ac.ir, jalil.mazloun@ssau.ac.ir

Abstract

One of the main reasons of death in the world, mostly affecting seniors, is brain stroke. Almost 85% of all brain strokes are ischemic due to internal bleeding in a part of the brain. Due the high mortality rate, quick diagnostic and treatment of ischemic and hemorrhagic strokes are of utmost importance. In this paper, to realize microwave brain imaging system, a circular array-based of modified bowtie antennas located around the multilayer head phantom with a spherical target with radius of 1 cm as intracranial hemorrhage target are simulated in CST simulator. To obtain satisfied radiation characteristics in the desired band (from 0.5-5 GHz) an appropriate matching medium is designed. First, in the processing section, a confocal image-reconstructing method based using delay and sum (DAS) and delay, multiply and sum (DMAS) beam-forming algorithms is used. The reconstructed images generated shows the usefulness of the proposed confocal method in detecting the spherical target in the range of 1 cm. The main purpose of this paper is stroke classification using deep learning approaches. For this, an image classification algorithm is developed to estimate the stroke type from reconstructed images. By using the proposed deep learning method, the reconstructed images are classified into different categories of cerebrovascular diseases using a multiclass linear support vector machine (SVM) trained with convolutional neural networks (CNN) features extracted from the images. The simulated results show the suitability of the proposed image reconstruction method for precisely localizing bleeding targets, with 89% accuracy in 9 seconds. In addition, the proposed deep-learning approach shows good performance in terms of classification, since the system does not confuse between different classes.

Keywords: confocal image reconstruction algorithm, convolutional neural network, support vector machine classifier, intracranial hemorrhage stroke detection, microwave head imaging system

Received: 23 November 2021

Revised: 15 January 2022

Accepted: 11 June 2022

Corresponding Author: Dr. Jalil Mazloun

Citation: M. Roohi, J. Mazloun, M.A. Pourmina, B. Ghalamkari, "Brain stroke classification based on deep learning approach in microwave brain imaging system", Journal of Intelligent Procedures in Electrical Technology, vol. 15, no. 57, pp. 121-132, June 2024 (in Persian).

طبقه‌بندی سگته مغزی بر اساس روش یادگیری عمیق در سیستم تصویربرداری ریزموجی از مغز

مجید روحی^۱، دانشجوی دکتری، جلیل مظلوم^۲، دانشیار، محمدعلی پورمینا^۱، دانشیار، بهمد قلمکاری^۱، استادیار

۱- دانشکده مهندسی برق- واحد علوم و تحقیقات تهران، دانشگاه آزاد اسلامی، تهران، ایران

۲- دانشکده مهندسی برق- دانشگاه علوم و فنون هوایی شهید ستاری، تهران، ایران

majid.roohi@srbiau.ac.ir, pourmina@srbiau.ac.ir, ghalamkari@srbiau.ac.ir, jalil.mazloum@ssau.ac.ir

چکیده: یکی از عوامل رایج مرگ‌ومیر در دنیا که بیشتر افراد مسن در معرض آن هستند، سگته مغزی است. حدود ۸۵ درصد از تمام سگته‌های مغزی، از نوع سگته مغزی ایسکمیک بوده و ناشی از خون‌ریزی داخلی بخشی از مغز است. با توجه به آمار بالای مرگ‌ومیر ناشی از سگته مغزی، تشخیص و درمان سریع سگته مغزی ایسکمیک و سگته مغزی هموروژیک بسیار مهم است. در این مقاله یک سیستم تصویربرداری میکروویو مغز، برای تشخیص خون‌ریزی داخل جمجمه کروی شکل با شعاع یک سانتی‌متر در نرم افزار CST شبیه‌سازی و برای تصویربرداری از یک سری آرایه آنتن پروانه‌ای اصلاح شده در اطراف فانتوم سر چند لایه، استفاده شده است. برای داشتن ویژگی‌های تشعشی مورد نظر در محدوده باند فرکانسی ۰/۵ الی ۵/۵ گیگاهرتز، یک محیط تطبیق مناسب طراحی شده است. ابتدا در بخش پردازش از روش‌های بازسازی تصویر مانند الگوریتم‌های بیمفرم تأخیر و جمع و همچنین تأخیر ضرب و جمع استفاده می‌شود. تصاویر بازسازی شده مفید بودن روش متداول پیشنهادی را در تشخیص هدف کروی در محدوده یک سانتی‌متر نشان می‌دهد. هدف اصلی این مقاله طبقه‌بندی سگته مغزی ایسکمیک و هموروژیک با استفاده از رویکردهای یادگیری عمیق است. برای این منظور یک الگوریتم طبقه‌بندی تصویر برای تخمین نوع سگته از تصاویر بازسازی شده ایجاد می‌شود که در این راستا با استفاده از روش پیشنهادی یادگیری عمیق تصاویر بازسازی شده توسط یک ماشین بردار پشتیبان خطی چند کلاسه با ویژگی استخراج شده توسط یک شبکه عصبی کانولوشن آموزش می‌بینند. نتایج شبیه‌سازی شده عملکرد مناسب روش پیشنهادی را در تعیین محل دقیق اهداف خون‌ریزی با دقت ۸۹ درصد و در مدت زمان ۹ ثانیه نشان می‌دهد. علاوه بر این، روش پیشنهادی یادگیری عمیق به دلیل سردرگم نبودن سیستم در بین طبقات مختلف از نظر طبقه‌بندی عملکرد خوبی را نشان می‌دهد.

کلمات کلیدی: تشخیص خون‌ریزی داخل جمجمه، سیستم تصویربرداری میکروویو سر، شبکه عصبی کانولوشن، طبقه‌بندی ماشین بردار پشتیبان، الگوریتم بازسازی تصویر کانفوکال

تاریخ ارسال مقاله: ۱۴۰۰/۹/۲

تاریخ بازنگری مقاله: ۱۴۰۰/۱۰/۲۵

تاریخ پذیرش مقاله: ۱۴۰۱/۳/۲۱

نام نویسنده‌ی مسئول: دکتر جلیل مظلوم

نشانی نویسنده‌ی مسئول: تهران- دانشگاه علوم و فنون هوایی شهید ستاری- دانشکده مهندسی برق

۱- مقدمه

اخیراً سیستم‌های تصویربرداری میکروویو^۱ به‌عنوان یک سیستم اسکن قابل حمل مغز، مورد توجه قرار گرفته شده است [۱-۵]. هدف از سیستم تصویربرداری میکروویو مغز برای کاربردهای مانند تشخیص تومور سرطانی، آسیب‌های مغزی ایسکمیک یا خون‌ریزی و نظارت بر فعالیت‌های مغزی است [۱،۲]. در این سیستم چندین فاکتور اصلی در عملکرد تصویربرداری نقش بسزایی دارند. این عوامل شامل بعد آنتن و ویژگی‌های تابش آن، روش‌های بازسازی تصویر، روش‌های پسا پردازش و غیره است. در مرجع‌های [۱] الی [۳] چندین روش تصویربرداری برای استفاده در سیستم‌های تصویربرداری پزشکی پیشنهاد شده است. به‌طور کلی روش‌های تصویربرداری به دو شاخه اصلی کمی و کیفی طبقه‌بندی می‌شوند. روش‌های کمی مانند توموگرافی، ثابت دی الکتریک منطقه مورد نظر^۲ را بر اساس روش‌های تکرار شونده استخراج می‌کند. تصویری که با استفاده از این روش‌ها بازسازی می‌شود، دارای هزینه زمان زیاد محاسبه ولی در مقابل تفکیک‌پذیری خوبی را دارد. از طرف دیگر روش‌های کیفی مانند روش‌های مبتنی بر رادار، بر اساس تاخیر سیگنال‌های منعکس شده بوده و به دلیل سریع‌تر بودن از روش‌های کمی از آنها به‌عنوان روش‌های زمان واقعی که مناسب‌تر برای استفاده در بیمارستان هستند، استفاده می‌شوند. روش‌های یادگیری ماشین که در سیستم‌های تصویربرداری میکروویو اعمال می‌شوند، توانایی بالایی در امکان تقسیم‌بندی، خوشه‌بندی و طبقه‌بندی دارند [۶-۱۵]. در مرجع [۸]، یک شبکه عصبی با تصویربرداری میکروویو برای یادگیری مدل رو به جلو برای یک سیستم پیچیده جمع‌آوری داده‌ها، ترکیب شده است. علاوه بر این در مرجع [۹] شبکه عصبی با عملکرد پایه شعاعی برای تخمین موقعیت و اندازه مغز تکثیر یافته در داخل بافت استخوان با تصویربرداری میکروویو پیشنهاد شده است. در مرجع [۱۰] سعی شده از یک شبکه عصبی عمیق برای ارتقاء تصاویر ساخته شده بهره‌مند شوند. شبکه عصبی عمیق آنها آموزش دیده شده بود تا از تصاویر میکروویو ایجاد شده با استفاده از روش پس‌بینی^۳ به عنوان ورودی استفاده کند و از آن یک تصویر بسیار بهتر داشته باشد. در حقیقت، نویسندگان تلاش کرده‌اند تا از روش‌های تکراری برای حل مسئله معکوس الکترومغناطیسی غیر خطی عبور کنند. اخیراً، استفاده از روش‌های یادگیری عمیق برای بهبود تصویربرداری میکروویو^۲ بعدی برای برنامه تصویربرداری پستان مورد بررسی قرار گرفته است [۱۱]. محققانی که از روش‌های مبتنی بر رادار استفاده می‌کنند، رویکردهای یادگیری ماشین برای تشخیص ضایعات پستان را نیز بررسی کرده‌اند [۱۲]. در مرجع [۱۳] یک روش طبقه‌بندی جدید برای تشخیص خودکار از تصویر بازسازی شده بر اساس توموگرافی میکروویو ارائه شده است، به‌عنوان مثال این روش می‌تواند برای تشخیص یک تومور سرطانی در داخل بافت پستان مورد استفاده قرار گیرد. در سیستم توموگرافی میکروویو تصویر بازسازی شده بر اساس خصوصیات دی الکتریک محیط ایجاد شده است. نوع دیگر طبقه‌بندی مستقیماً بر اساس ویژگی سیگنال، بدون بازسازی خاصیت دی الکتریک استوار است. به‌عنوان مثال، یک روش جدید برای طبقه‌بندی خون‌ریزی هموروژیک^۴ از سگته مغزی ایسکمیک^۵ در مرجع [۱۵] ارائه شده است.


در این مقاله مزایای استفاده از روش یادگیری عمیق برای تشخیص و طبقه‌بندی دو نوع سگته مغزی در مدل دقیق فانتوم سر کامل در سیستم تصویربرداری میکروویو چند استاتیک مورد بررسی قرار گرفته است. برای این منظور، یک آرایه دایره‌ای شکل از آنتن‌های پروانه‌ای در اطراف مدل سر ناسالم قرار داده شده است تا از ۰/۵ گیگاهرتز تا ۵ گیگاهرتز را پوشش دهد. سیگنال‌های منعکس شده از کانال‌های مختلف چند استاتیک جمع‌آوری شده، سپس به عنوان ورودی در الگوریتم بازسازی تصویر کانفوکال، برای نقشه برداری از اطلاعات استخراج شده در تصاویر^۲ بعدی استفاده می‌شود. به دلیل اهمیت خوشه‌بندی برای تشخیص سگته مغزی خون‌ریزی هموروژیک از ایسکمیک، پس از ایجاد تصویر از منطقه مورد نظر، از یک روش پسا پردازش ترکیبی جدید استفاده می‌شود. به این منظور، الگوریتم استخراج ویژگی با استفاده از شبکه عصبی کانولوشن^۶ اعمال می‌شود. سپس، طبقه‌بندی ماشین بردار پشتیبان^۷ برای طبقه‌بندی استفاده می‌شود. نتایج به‌دست آمده توسط سیستم تصویربرداری پیشنهادی نشان می‌دهد که استفاده از روش یادگیری عمیق پیشنهادی، توانایی خوبی در تشخیص دو نوع سگته ذکر شده در تصاویر مبتنی بر رادار با ابهام زیاد را دارد.

۲- پیکربندی سیستم تصویربرداری مغز

در این بخش سناریوی تصویربرداری میکروویو مغز برای ایجاد ارتباط بین رویکرد یادگیری عمیق و اثبات اثربخشی آن در طبقه‌بندی سگته مغزی توصیف می‌شود. سناریوی تصویربرداری میکروویو مغز شبیه‌سازی شده در شکل (۱) نشان داده شده

است. تحقق سناریوی تصویربرداری مایکروویو مغز شامل سه سطح اصلی است. مطابق یک رویکرد از پایین به بالا در سطح اول ۱۶ آنتن در اطراف فانتوم کامل قرار دارند که موج الکترومغناطیسی را در دامنه فرکانس ۰/۵ تا ۵ گیگاهرتز تابش می‌کنند. در سطح بعدی، الگوریتم بازسازی تصویری کانفوکال قرار دارد که می‌تواند موج منعکس شده از پوست در مرز فانتوم سر را به حداقل برساند. یک محیط تطبیق مناسب بین آنتن‌ها و فانتوم سر نیز طراحی شده است. این لایه خاص می‌تواند به افزایش عمق نفوذ موج منتقل شده در داخل فانتوم سر کمک کند.

همان‌طور که در شکل (۱) نشان داده شده برای تحقق سیستم تصویربرداری پیشنهادی مدل چند لایه‌ای فانتوم سر انسان در نرم افزار CST ایجاد شده است [۱۶]. فانتوم سر مورد استفاده شامل تمام جزئیات تشریحی سر انسان از لایه پوست تا ماده سفید مغزی برای سهولت در مدل‌سازی و تصویربرداری است. تمام خصوصیات الکتریکی مواد فانتوم سر استفاده شده در جدول (۱) آمده است. همچنین همان‌طور که در شکل (۱) مشاهده می‌شود، از شانزده آنتن پیشنهادی که سر را در فاصله‌های مساوی ۱۰ میلی‌متر از لایه پوست محاصره می‌کنند و یک سکنه مغزی خون‌ریزی که در داخل سر قرار دارد در مدل استفاده شده است. طراحی یک چارچوب انتشار مناسب که شامل آنتن، محیط تطبیق و مدل مغز است مرحله مهم در تنظیم تصویربرداری مایکروویو مغز است. در این مقاله، با محافظت از آنتن‌ها در محیط تطبیق مناسب طراحی شده اثرات عدم تطابق بین آنتن و فانتوم سر کاهش می‌یابد [۱۷]. مدلی که برای شبیه‌سازی استفاده شده، مدل مولتی استاتیک است. به عبارتی در هر مرحله فقط یک آنتن فرستنده و یک آنتن گیرنده فعال وجود دارد به این ترتیب هیچ نوع اثر متقابل امواج ایجاد شده روی آنتن‌های کناری در سیگنال‌های دریافتی وجود ندارد. برای اطمینان از تطبیق الکتریکی بین آنتن‌ها و منطقه تحت آزمایش، یک محیط انتقال بر اساس جاروکردن پارامتری ویژگی‌های الکتریکی طراحی شده است. مشخصات الکتریکی محاسبه شده برای این محیط مقدار گذردهی الکتریکی نسبی برابر ۲۰ و مقدار ضریب رسانایی ماده برابر ۰/۵ زیمنس بر متر است.




شکل (۱): طراحی و نحوه چیدمان آنتن‌ها در تصویربرداری مایکروویو از مغز

Figure (1): The proposed microwave imaging setup and design of the antenna.

Table (1): Rical caractelectedrics of the multi-layer brain phantom

جدول (۱): خصوصیات الکتریکی لایه‌های مختلف مغز

لایه	عمق (میلی‌متر)	شعاع داخلی (میلی‌متر)	شعاع خارجی (میلی‌متر)
پوست	۲	۸۰	۱۲۰
چربی	۱/۴	۷۸	۱۱۸
جمجمه	۴/۱	۷۶/۶	۱۱۶/۶
مایع مغزی-نخاعی	۰/۵	۷۳/۴	۱۱۳/۴
ماده خاکستری	۷	۷۲/۹	۱۱۲/۹
ماده سفید	بخش داخلی	۶۵	۱۰۵
خون	۱۰	۱۰	--



شکل (۲): شش نمونه از خصوصیات سیگنال‌های بازتابی شبیه‌سازی شده آنتن پیشنهادی در درون محیط تطبیق طراحی شده
Figure (2): Six samples of the simulated return loss characteristics of the proposed antennas inside the proposed matching medium

شش نمونه از خصوصیات سیگنال‌های بازتابی شبیه‌سازی شده آنتن پیشنهادی در موقعیت‌های مختلف درون محیط تطبیق طراحی شده در شکل (۲) نشان داده شده است. از شکل (۲) مشاهده می‌شود که با یک انتخاب مناسب برای میزان مجاز و هدایت محیط تطبیق تمام شانزده آنتن از ۰/۵ تا ۵ گیگاهرتز تابش می‌شوند.

۳- الگوریتم بازسازی تصویر در سیستم تصویربرداری مغز مایکروویو

در این بخش برای نشان دادن امکان سیستم تصویربرداری مایکروویو مبتنی بر رادار در تشخیص سگته مغزی از الگوریتم تصویربرداری کانفوکال استفاده شده و نتایج تجزیه و تحلیل شده است. بدیهی است که تشخیص خون‌ریزی در سگته مغزی امری اضطراری بوده و لازم است که به‌صورت زمان واقعی در نظر گرفته شود. پس از شبیه‌سازی و تنظیمات سیستم تصویربرداری طراحی شده، تمام سیگنال‌های منعکس شده برای بازسازی تصاویر در نرم‌افزار متلب ذخیره می‌شوند. این روند شامل سه بخش اصلی پیش-پردازش، پردازش و پسا-پردازش است. در بخش پیش-پردازش، هدف اصلی کالیبراسیون سیگنال‌های منعکس شده حذف کلاتر است. بخش پردازش شامل یکپارچه‌سازی منسجم مبتنی بر الگوریتم تاخیر و جمع^۸ است. سرانجام در پسا-پردازش از الگوریتم یادگیری عمیق برای تشخیص نوع سگته مغزی استفاده می‌شود. برای ادغام سیگنال منسجم، باید تأخیرهایی را که به دلیل ساختار چند ایستایی در سیگنال‌های منعکس شده در مسیرهای مختلف وجود دارد، جبران کرد. بنابراین در مرحله اول کالیبراسیون پیشنهادی باید تاخیر در وضعیت آنتن در نظر گرفته شود. برای این مورد، باید تغییر فاز بین هر آنتن با بقیه را پیدا کرد. این زمان تاخیر برابر با فاصله مستقیم بین فرستنده و گیرنده تقسیم بر سرعت موج در محیط اتصال است [۱۸]. مرحله بعدی استخراج محل خون‌ریزی سگته مغزی از سیگنال‌های منعکس شده است. پس از شناسایی این نقطه، برای جبران این تاخیر ابتدا قبل از تأخیرهای محاسبه شده همه مقادیر را صفر در نظر گرفته می‌شود. در مورد تصویربرداری چند ایستایی میدان نزدیک برای بازسازی یک تصویر، باید یک الگوریتم شکل دهنده پرتو متمرکز مانند الگوریتم تابش شکل کانونی را اعمال کنیم. برای این منظور، اولین قدم شناسایی نقاط کانونی برای محاسبه الگوی انرژی سیگنال منعکس شده در این نقاط است که برای الگوریتم تصویربرداری چند ایستایی با ادغام سیگنال‌های منسجم انجام می‌شود. با توجه به بعد و عرض پالس، ۳۲۰ نقطه کانونی در داخل منطقه مورد نظر در نظر گرفته شده است.

همان‌طور که بیان شد به‌منظور ایجاد تصویر بر اساس سیگنال‌های دریافتی از الگوریتم بازسازی تصویر کانفوکال تاخیر و جمع استفاده شده است [۱۹]. برای افزایش دقت در تشخیص هدف، از یک بیمفرم بهبود یافته به نام تأخیر ضرب و جمع^۹ استفاده شده است. بیمفرم تاخیر و جمع بر اساس جابجایی سیگنال‌های منعکس شده در حوزه زمان برای ایجاد یک سیگنال هم‌دوس کار می‌کند. نهایتاً با جمع‌بندی نتایج می‌توان انرژی را در نقاط کانونی محاسبه کرد. در این مقاله بر اساس مدل‌سازی افت مسیر در سیگنال‌های منعکس شده مقدار ۳۶ به عنوان بهترین انتخاب برای تأثیر پذیری موثر در ساختار چند لایه پیشنهادی محاسبه شده است. برای استفاده از الگوریتم بازسازی تصویر کانفوکال با داشتن M آنتن و با در نظر گرفتن S_n به عنوان آمین سیگنال برگشتی، انرژی در هر موقعیت کانونی r را می‌توان به‌صورت زیر نشان داد:

$$I(r) = \int_0^{T_w} \left[\sum_{i=1}^M S_n(t - \tau_i(r)) \right]^2 dt \quad r = [x; y; z] \quad (1)$$

که در آن:

$$\tau_i(r) = \frac{2d_i(r)}{vT_s} \quad (2)$$

$$d_i(r) = |r - r_i| \quad (3)$$

است. $\tau_i(r)$ به عنوان تأخیر زمانی گسسته نشان داده می‌شود. در این حالت $d_i(r)$ فاصله زمانی گسسته از آنتن منتقل کننده r_n تا نقطه کانونی r را نشان می‌دهد، v نشانگر سرعت متوسط موج منتشر شده در محیط مغز است، T_w طول پنجره است و T_s فاصله نمونه‌گیری است. در یک سیستم چند مرحله‌ای می‌توان M^2 سیگنال‌های را ثبت کرد. اما برای محاسبه مشخصات انرژی فقط $M(M-1)/2$ سیگنال مورد نیاز است. یکی دیگر از پرتوهای مفید برای الگوریتم بازسازی تصویر کانفوکال، پرتو تأخیر، ضرب و جمع است [۲۰]. این الگوریتم مانند تأخیر و جمع، شامل سیگنال‌های تغییر یافته در زمان و جفت سیگنال‌های ضرب شده است که به منظور محاسبه انرژی در یک نقطه کانونی جمع می‌شوند. انرژی مربوط به نقطه کانونی r در محیط مغز به صورت زیر تعریف می‌شود:

$$I(r) = \int_0^{T_w} \left[\sum_{i=1}^{M-1} \sum_{j=n+1}^M S_n(t - \tau_i(r)) S_j(t - \tau_j(r)) \right]^2 dt \quad (4)$$


که در آن M تعداد آنتن‌ها در تصویربرداری چند استاتیکی است. در روش بازسازی تصویر کانفوکال، شدت (روشنایی) پیکسل تصویر در n امین محدوده سلول و جهت θ با $F_i(n)$ مطابق رابطه زیر نشان داده می‌شود:

$$F_i(n) = \sum_{n=1}^N f_i X_i(n) e^{j\theta_i} \quad (5)$$

در این مقاله فرض شده است که جبهه موج کروی برای موج منتشر شده در داخل محیط مغز است. در معادله (۵)، $X_i(n)$ سیگنال دریافتی از آنتن و N تعداد کل آنتن‌های دریافت کننده است. همچنین برای در نظر گرفتن اثرات محیطی، میرایی و تلفات انتشار، f_i را به عنوان پارامتر وزن اضافه شده است. به منظور جبران اختلاف فاز ناشی از مسیرهای متفاوت، از مؤلفه فاز φ_i استفاده می‌شود [۲۱]. از طریق پردازش داده‌های خام، تصویر بازسازی شده ۲ بعدی با استفاده از سناریوی تصویربرداری دیفرانسیل، با کم کردن تصویر مغز سالم از مغز همراه با سکنه مغزی، در شکل (۳) نشان داده شده است. همان‌طور که قبلاً ذکر شد از معادله مرسوم کانفوکال تأخیر و جمع استفاده شده است. همان‌طور که در شکل (۳) نشان داده شده است، نتیجه بازسازی شده از وضوح و کنتراست خوبی برای تعیین ناحیه مورد انتظار در محل خون‌ریزی سکنه مغزی برخوردار است.

۴- روش ترکیبی شبکه عصبی کانولوشن - ماشین بردار پشتیبان برای طبقه‌بندی تصاویر

یک چالش اساسی در طراحی روش یادگیری عمیق برای سیستم تصویربرداری میکروویو مغز، تعیین نوع سکنه مغزی است. این چالش را می‌توان مربوط به تصویر بازسازی شده از سیگنال‌های دریافتی دانست. به منظور پرداختن به این موضوع از ترکیب روش شبکه عصبی کانولوشن برای استخراج ویژگی و روش طبقه‌بندی ماشین بردار پشتیبانی به عنوان طبقه‌بند استفاده شده است. در این بخش روش طبقه‌بندی انواع سکنه مغزی برای سیستم تصویربرداری میکروویو مغز بر اساس شبکه‌های عصبی کانولوشن و ماشین بردار پشتیبان ارائه شده است. همچنین در این رویکرد از توصیف شبکه‌های عصبی باقیمانده کمک گرفته شده است. شبکه عصبی باقیمانده^{۱۰} یک شبکه عصبی مصنوعی^{۱۱} با تکیه بر ساختارهای شناخته شده از سلول‌های هرمی در قشر مغز است. شبکه عصبی باقیمانده اخیراً به دلیل عملکرد بسیار خوب در تشخیص تصویر، محبوبیت زیادی کسب کرده است. روش خاص در نظر گرفته شده براساس نقشه برداری باقیمانده امکان دستیابی به نتایج بهتر را در مرحله آموزش فراهم می‌کند [۲۲]. به‌طور خاص، مدل‌های شبکه عصبی باقیمانده مبتنی بر اتصالات/میانبرها هستند که به شما اجازه عبور از بعضی لایه‌ها را می‌دهند.




شکل (۳): تصویر بازسازی شده از روش بازسازی تصویر کانفوکال

Figure (3): Reconstructed image from confocal image reconstruction method with, (a) DAS beamforming, (b) DMAS beamforming

مدل‌های معمول این شبکه با پرش‌های دو یا سه لایه که حاوی غیرخطی بودن و نرمال‌سازی دسته‌ای در این بین هستند، اجرا می‌شوند. بلوک اصلی یادگیری باقیمانده با اتصال پرشی در شکل (۴) نشان داده شده است. معماری شبکه عصبی باقیمانده برای طبقه‌بندی تصویر، رگرسیون و استخراج ویژگی مناسب است. این معماری، از اتصالات پرشی استفاده می‌کند تا یک گروه از ورودی‌های کانولوشن را به خروجی خود اضافه کند. "اتصال پرش" نشان داده شده در شکل (۴) هسته اصلی اجرای شبکه عصبی باقیمانده بوده، که این ایده‌ی ساخت شبکه‌ای متشکل از شاخه‌هایی با اتصالات پرشی است. برای هر شاخه، اختلاف، نقشه فعال سازی باقیمانده بین ورودی و خروجی در هر شاخه، توسط الگوریتم آموزش داده می‌شود. این نقشه فعال سازی باقیمانده همراه با نقشه‌های فعال سازی قبلی جمع شده و "دانش جمعی" شبکه عصبی باقیمانده را ایجاد می‌کنند. آموزش شبکه‌های عصبی عمیق‌تر در طول تاریخ دشوار بوده است. یادگیری باقیمانده با اتصالات پرشی امکان آموزش مدل‌های عمیق‌تر را از هر زمان دیگری فراهم می‌کند، به طوری که شبکه‌هایی با عملکرد بالا با بیش از ۱۰۰۰ لایه به وجود آورده است. برای اکثر مدل‌های اخیر مشاهده می‌شود که مدل‌های عمیق‌تر از قدرت بیشتری برخوردار هستند. این نقشه شناسایی هیچ پارامتری ندارد و فقط برای افزودن خروجی از لایه قبلی به لایه پیش‌رو استفاده می‌شود. با این حال گاهی اوقات x و $F(x)$ ابعاد یکسانی نخواهند داشت. نگاشت هویت یا همان نقشه‌شناسایی در یک ضرب تصویرسازی خطی W ضرب می‌شود تا کانال‌های میانبر برای مطابقت با باقیمانده گسترش یابد [۲۳]. این کار اجازه می‌دهد تا x و $F(x)$ به عنوان ورودی به لایه بعدی ترکیب شوند.

$$y = F(x, \{W_i\}) + W_s \cdot x \quad (6)$$

معادله داده شده زمانی استفاده می‌شود که x دارای ابعاد متفاوتی مانند 32×32 و 30×30 داشته باشد. W_s را می‌توان با کانولوشن 1×1 پیاده‌سازی کرد که پارامترهای اضافی را به مدل معرفی می‌کند. در این مقاله ویژگی استخراج شده از شبکه عصبی باقیمانده، به عنوان ورودی در ماشین بردار پشتیبان استفاده می‌شود. ماشین بردار پشتیبان به عنوان طبقه‌بندی‌کننده خطی با بیشترین فاصله در فضای ویژگی تعریف می‌شود [۲۵]. فرایند اصلی در ماشین بردار پشتیبان یافتن یک ابرصفحه بهینه در فضای ویژگی است که ویژگی‌های طبقه‌بندی را به حداکثر می‌رساند.



شکل (۴): ساختار یادگیری باقیمانده با اتصال پرش [۲۴]

Figure (4): The building block of residual learning with skip connection.

مفهوم حداکثر حاشیه با صفحات محدودکننده و بردارهای پشتیبان در شکل (۵) نشان داده شده است. مرز تصمیم‌گیری با معادله (۷) که در شکل (۵) نشان داده شده به‌عنوان خط مرکزی می‌تواند توسط یک بردار عادی از ابرصفحه و یک افسست تعریف شود.

$$f(x) = w_T x + b \quad (7)$$

در این مقاله، هدف اصلی شناسایی بافت سالم از نمونه‌های سکنه مغزی است که یک مسئله سه کلاسه هست. مسئله مجموعه داده‌های آموزشی جداکننده را سه کلاسه، Z^i یک بردار ویژگی و y_i را برچسب کلاس در نظر بگیرید. اگر فرض کنید که هر یک از کلاس‌ها را می‌توان با یک ابرصفحه با معادله (۸) در فضای داده شده H از هم جدا کرد:

$$w \cdot z + b = 0 \quad (8)$$

آنگاه عملکرد تابع تصمیم‌گیری طبقه‌بندی را می‌توان به‌صورت زیر نوشت:

$$f(z) = \text{sign}(w \cdot z + b) \quad (9)$$

با این دیدگاه، ابرصفحه بهینه، ابرصفحه‌ای است که حاشیه γ را به حداکثر برساند:

$$\gamma = \frac{y \cdot f(z)}{\|w\|} \quad (10)$$

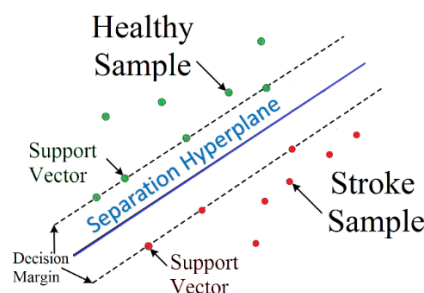
که این مسئله بهینه‌سازی به‌صورت زیر تعریف می‌شود:

$$\max_{w,b} \gamma \text{ s.t. } y_i \cdot f(z^i) > 1, y_i \in \{-1, +1\}, z^i \in R_k \quad (11)$$

مقادیر بهینه برای w و b را می‌توان با حل یک مسئله حداقل‌سازی با استفاده از ضریب لاگرانژ به‌دست آورد. برای مجموعه آموزشی، از بردارهای ویژگی استخراج شده از شبکه عصبی کانولوشن، برای ساختار طبقه‌بندی ماشین بردار پشتیبان استفاده می‌شود. سپس بخشی از آنها برای آزمایش مجموعه استفاده می‌شود، که به ارزیابی طبقه‌بندی ماشین بردار پشتیبان کمک می‌کند. در ادامه جزئیات روش ترکیبی شبکه عصبی کانولوشن-ماشین بردار پشتیبان بررسی خواهد شد. شماتیک ارائه شده در شکل (۶) سه سطح اصلی الگوریتم پیشنهادی را نشان می‌دهد. به‌طور خاص، روش پیشنهادی شامل یک شبکه عصبی کانولوشن از قبل آموزش دیده است، که به‌عنوان استخراج کننده ویژگی برای آموزش طبقه‌بندی تصویر استفاده می‌شود. شبکه عصبی کانولوشن با استفاده از سه مجموعه از تصاویر شامل دسته طبیعی یا سالم، ایسکمیک و خون‌ریزی شده یا هموروژیک آموزش می‌بیند. از این مجموعه‌ها، شبکه عصبی کانولوشن می‌تواند با نمونه‌های قوی که نماینده یک محدوده از تصاویر هست، آموزش ببیند [۲۵]. یک روش آسان برای استفاده از قدرت شبکه عصبی کانولوشن، بدون صرف وقت و تلاش برای آموزش، استفاده از شبکه عصبی کانولوشن از قبل آموزش دیده به‌عنوان یک استخراج کننده ویژگی است.

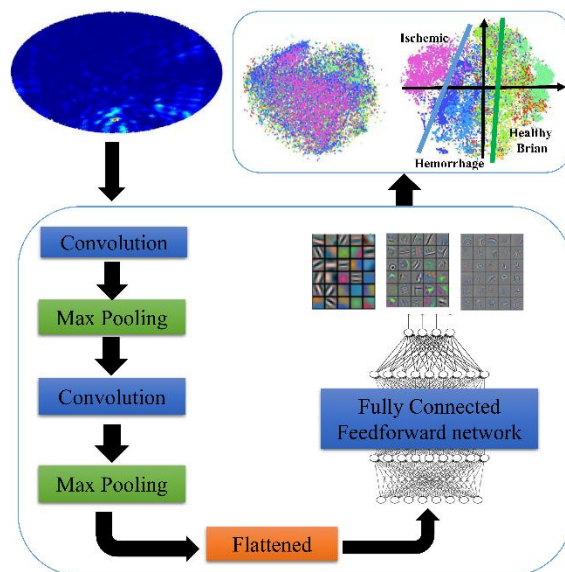
۵- ارزیابی عملکرد

بر اساس چارچوب فوق‌الذکر، اولین مرحله بارگذاری تصویر تست است. سپس با استفاده از شبکه عصبی کانولوشن برای استخراج یک سری ویژگی‌ها، سرعت پردازش و قدرت طبقه‌بندی بهبود می‌یابد.



شکل (۵): مفهوم حداکثر حاشیه با صفحات محدود کننده در طبقه‌بندی ماشین بردار پشتیبان

Figure (5): The concept of maximum margin with bounding planes and support vectors in Support vector machine (SVM) classifier.




شکل (۶): بلوک دیاگرام روش پیشنهادی یادگیری عمیق با روش شبکه عصبی کانولوشن به عنوان استخراج گر ویژگی و طبقه‌بند ماشین بردار پشتیبان برای طبقه‌بندی سکته مغزی

Figure (6): Multi-scale schematic of the proposed deep learning method based on CNN feature extractor and SVM classifier for stroke classification

بر اساس این ورودی‌ها چالش اصلی، در نظر گرفتن وزن مربوط به لایه‌های کانولوشن است. در شکل (۷)، شش تصویر مختلف استخراج شده از سه دسته مختلف (ورودی برنامه یادگیری ماشین) را نشان داده شده است. برای شبیه‌سازی اهداف خون‌ریزی، از مواد شبه خون استفاده شده است. در حالی که اهداف ایسکمیک با موادی با نفوذ پذیری الکتریکی ۱۵ درصد کمتر از خون مدل شده است. این روش برای طبقه‌بندی یک بردار ویژگی از هر تصویر را استخراج می‌کند و طبقه‌بندی بر مبنای این ویژگی‌ها انجام می‌گیرد. تصاویر خاص بر اساس سناریوی‌های مختلف شبیه‌سازی شده‌اند. همچنین از مدل شبکه عصبی باقیمانده (۵۰) برای شبکه عصبی کانولوشن از جعبه ابزار یادگیری عمیق در متلب استفاده شده است [۲۶]. پس از فراخوانی تصاویر بازسازی شده در برنامه متلب، ابتدا آنها متناسب با نوع تصویر برچسب‌های متناظر را دریافت می‌کند، در جدول (۲) تعداد این دسته‌ها همراه با تعداد نمونه‌های تصاویر در هر دسته‌بندی نشان داده شده است.

برای تخمین نوع سکته برای هر تصویر ورودی، برای هر گروه مورد طبقه‌بندی انواع مختلف سکته تعریف می‌شوند. شکل (۷) شش نمونه از این تصاویر را که در سه دسته متفاوت طبقه‌بندی شده‌اند را نشان می‌دهد. برنامه به‌طور خودکار عمل کرده، به‌طوری‌که تصویر مورد تست به‌عنوان ورودی گرفته می‌شود و سپس الگوریتم شبکه‌های عصبی از طریق یادگیری عمیق برای استخراج ویژگی هر تصویر استفاده می‌شود. شبکه عصبی پیشنهادی در این مطالعه از کلاس "fc1000" برای استخراج ویژگی‌هایی استفاده می‌کند که توانایی تشخیص لبه‌ها و لکه‌ها را دارند. در پیکربندی شبکه عصبی کانولوشن ساخته شده، اولین لایه کانولوشن مطابق تصویر ورودی وزن دهی می‌شود [شکل (۸)]. ویژگی‌های استخراج شده به عنوان ورودی برای برنامه طبقه‌بندی ماشین بردار پشتیبان استفاده می‌شوند. برخی از این ویژگی‌ها برای آموزش (۷۰ درصد) و برخی دیگر برای آزمایش (۳۰ درصد) برنامه طبقه‌بندی استفاده می‌شود. برای طبقه‌بندی از یک برنامه چند کلاسه ماشین بردار پشتیبان استفاده می‌شود.

جهت بررسی قابلیت طبقه‌بندی الگوریتم پیشنهادی، یک تصویر همان‌طور که در شکل (۹) نشان داده شده است به‌عنوان ورودی به برنامه داده شده است که دارای هدف هموراژیک است. در این شکل منطقه مربوط به هدف مشخص شده است. برنامه به درستی توانسته نوع کلاس مربوط به تصویر را تشخیص دهد که با یک پیام نهایی این کلاس بندی به صورت زیر چاپ می‌شود: "The loaded image belongs to Hemorrhagic class" به‌منظور ارزیابی روش پیشنهادی، یک ماتریس درهم‌ریختگی^{۱۲} ایجاد شده که در جدول (۳) نشان داده شده است. به‌طور خاص، سه برچسب جدول (۲)، در نظر گرفته شده است. هر ردیف جدول (۳) بیانگر نتایج پیش‌بینی شده و هر ستون بیانگر نتایج واقعی است.




شکل (۷): شش نمونه از تصاویر ورودی در سه دسته مختلف برای استخراج ویژگی‌ها با استفاده از شبکه عصبی کانولوشن به‌عنوان ورودی طبقه‌بند ماشین بردار پشتیبان، (الف) عادی، (ب) ایسکمیک، و (ج) هموروژیک

Figure (7): Six samples of the input images inside three different categories for extracting the features using CNN as input of SVM classifier, (a) Normal, (b) Ischemic, (c) Hemorrhagic.

Table (2): Three labels of the input images categories

جدول (۲): برچسب تصاویر ورودی


تعداد	برچسب
۱۱	بافت نرمال (سالم)
۷	سکته هموروژیک
۸	سکته ایسکمیک



شکل (۸): وزن اولین لایه کانولوشن

Figure (8): The first convolution layer weights.

در این جدول، مقادیر نرمالیزه گزارش شده است. از نتایج جدول (۳) مشاهده می‌شود که روش پیشنهادی از نظر تشخیص، عملکرد خوبی را نشان می‌دهد، زیرا سیستم در بین طبقات مختلف خطای تشخیص پایینی دارد. فقط اختلاف کمی در دسته سوم وجود دارد، که می‌تواند با افزودن تعداد بیشتر نمونه در دسته مرتبط، قابل حل باشد. همان‌طور که از نتایج جدول مشاهده می‌شود، الگوریتم پیشنهادی توانایی جداسازی بهینه بافت طبیعی و سکته مغزی را دارد.



شکل (۹): تصویر بارگذاری نمونه جهت تست به همراه محل عارضه سگته
Figure (9): The reconstructed image including the reference target's location

در جداسازی دو نوع سگته مغزی (ایسکمیک و خون‌ریزی دهنده) خطایی وجود دارد که به دلیل تفاوت اندک بین هدایت الکتریکی دو نوع سگته مغزی است. برای کاهش خطا (بهبود دقت تفکیک)، به تعداد زیادی نمونه در هر دسته نیاز است. به منظور نشان دادن عملکرد طبقه‌بند، در جدول (۴) مقایسه‌ای بین نتایج پس از پردازش روش پیشنهادی و مقاله‌های مشابه اخیر منتشر شده انجام شده است. مشاهده می‌شود روش پیشنهادی عملکرد مناسبی را نسبت به روش‌های دیگر دارد. منظور از عملکرد مناسب روش پیشنهادی لزوماً فقط پارامتر صحت نبوده و مجموع پارامترها از قبیل زمان (که نقش اساسی دارد)، تعداد نمونه کم نسبت به روش‌های دیگر، بردار ویژگی ساده‌تر و از همه مهم‌تر تهیه نمونه‌های مختص این کاربرد که منجر به ایجاد یک پایگاه داده تخصصی شده، در نظر گرفته شده است. لازم به ذکر است که اگر تعداد تصاویر با روش‌های دیگر تصویربرداری ادغام و تعداد نمونه‌ها افزایش یابد صحت آشکارسازی به ۹۷ درصد خواهد رسید [۲۸]. بنابراین می‌توان نتیجه گرفت که روش پیشنهادی قابلیت خوبی برای طبقه‌بندی اهداف تصاویر مغزی با استفاده از فن‌آوری ریزموج دارد. این الگوریتم با استفاده از نرم‌افزار متلب ۲۰۱۹ در یک پردازنده اینتل Core™ i7 با فرکانس ۳/۶۰ گیگاهرتز مبتنی بر سیستم عامل ویندوز ۱۰، ۶۴ بیتی انجام شد و دارای ۷۸۵۶ مگابایت واحد پردازش گرافیکی (GPU) NVIDIA است.

Table (3): The extracted confusion matrix

جدول (۳): ماتریس درهم‌ریختگی

		برچسب‌های واقعی		
		بافت نرمال (سالم)	سگته هموروژیک	سگته ایسکمیک
برچسب‌های پیش‌بینی شده	بافت نرمال	۱	۰	۰
	سگته هموروژیک	۰	۱	۰
	سگته ایسکمیک	۰	۰/۳۳۷	۰/۶۶۷

Table (4): Comparison of the proposed method to other published similar papers in the literature

جدول (۴): مقایسه روش پیشنهادی با سایر مقالات مشابه منتشر شده

مشخصات پردازنده	زمان (ثانیه)	سطح سیگنال به نویز (dB)	تعداد ویژگی‌های استخراج شده	دقت طبقه‌بند (درصد)	روش
core i7@1.8 GHz	۹	۲۸	۱۰۰۰	۸۹	پیشنهادی
Not mentioned	۳۱	بدون نویز	۳	۹۶/۱	مرجع [۱۱]
core i7@3.6 GHz	اعلام نشده است	بدون نویز	۷	۹۳	مرجع [۱۲]
core i7@3.4 GHz	۱۰	۴۵، ۲۵، ۱۰	۳	۸۸	مرجع [۲۷]

۶- نتیجه‌گیری

هدف اصلی این مطالعه طبقه‌بندی انواع سگته مغزی در تصاویر بازسازی شده از سیستم تصویربرداری مایکروویو مغز است. به این منظور، یک روش مبتنی بر یادگیری عمیق برای پیش‌بینی نوع سگته مغزی ارائه شده است. به‌طور خاص روش پیشنهادی شامل یک شبکه عصبی کانولوشن و طبقه‌بندی کننده ماشین بردار پشتیبان از قبل آموزش دیده شده است. رویکردی که در این مقاله به آن پرداخته شده امیدوار کننده بوده و امکان طبقه‌بندی دقیق با سرعت بالا را در سیستم‌های تصویربرداری مایکروویو نشان می‌دهد. در آینده برای بهبود دقت، پیشنهاد ترکیب این روش با سایر روش‌های یادگیری ماشین مانند الگوریتم ژنتیک مطرح است. همچنین سناریوهای دیگری که به پیچیده‌تر شدن مدل‌سازی بافت بیولوژیکی می‌انجامد، می‌تواند در نظر گرفته شود.

سپاسگزاری

این مقاله مستخرج از رساله دکتری در دانشگاه آزاد اسلامی واحد علوم و تحقیقات است. نویسندگان بر خود لازم می‌دانند مراتب تشکر صمیمانه خود را از همکاران حوزه پژوهشی دانشگاه آزاد اسلامی و داوران محترم که ما را در انجام و ارتقای کیفی این مقاله یاری نموده‌اند، اعلام نمایند.

References

مراجع

- [1] R. Scapaticci, J. Tobon, G. Bellizzi, F. Vipiana, L. Crocco, "Design and numerical characterization of a low-complexity microwave device for brain stroke monitoring", *IEEE Trans. on Antennas and Propagation*, vol. 66, pp. 7328-7338, Dec. 2018 (doi: 10.1109/TAP.2018.2871266).
- [2] B. Sohani, G. Tiberi, N. Ghavami, M. Ghavami, S. Dudley, A. Rahimi, "Microwave imaging for stroke detection: validation on head-mimicking phantom", *Proceeding of the IEEE/PIERS*, pp. 940-948, Rome, Italy, June 2019 (doi: 10.1109/PIERS-Spring46901.2019.9017851).
- [3] J. Wang, X. Jiang, L. Peng, X. Li, H. An, B. Wen, "Detection of neural activity of brain functional site based on microwave scattering principle", *IEEE Access*, vol. 7, pp. 13468-13475, Jan. 2019 (doi: 10.1109/ACCESS.2019.2894128).
- [4] M. Ilja, A. Massa, D. Vrba, O. Fiser, M. Salucci, J. Vrba, "Microwave tomography system for methodical testing of human brain stroke detection approaches", *International Journal of Antennas and Propagation*, vol. 2019, pp. 1-9, Mar. 2019 (doi: 10.1155/2019/4074862).
- [5] A. Santorelli, E. Porter, E. Kirshin, Y.J. Liu, M. Popovic "Investigation of classifiers for tumor detection with an experimental time domain breast screening system", *Progress in Electromagnetics Research*, vol. 144, pp. 45-57, 2014 (doi: 10.2528/PIER13110709).
- [6] T. Pokorny, J. Tesarik, "Microwave stroke detection and classification using different methods from matlab's classification learner toolbox", *Proceeding of the IEEE/EuMCR*, pp. 500-503, Prague, Czech Republic, May. 2019.
- [7] R.C. Conceicao, M. O'Halloran, M. Glavin, E. Jones, "Support vector machines for the classification of early-stage breast cancer based on radar target signatures", *Progress in Electromagnetics Research B*, vol. 23, pp. 311-327, 2010 (doi: 10.2528/PIERB10062407).
- [8] Y.A. Rahama, O.A. Aryani, U.A. Din, M.A. Awar, A. Zakaria, N. Qaddoumi, "Novel microwave tomography system using a phased-array antenna", *IEEE Trans. on Microwave Theory and Techniques*, vol. 66, pp. 5119-5128, Aug. 2018 (doi: 10.1109/TMTT.2018.2859929).
- [9] I.T. Rekanos, "Neural-network-based inverse-scattering technique for online microwave medical imaging", *IEEE Trans. on Magnetics*, vol. 38, no. 2, pp. 1061-1064, Mar. 2002 (doi: 10.1109/20.996272).
- [10] L. Li, L.G. Wang, F.L. Teixeira, C. Liu, A. Nehorai, T.J. Cui, "DeepNIS: Deep neural network for nonlinear electromagnetic inverse scattering", *IEEE Trans. on Antennas and Propagation*, vol. 67, no. 3, pp. 1819-1825, Mar. 2019 (doi: 10.1109/TAP.2018.2885437).
- [11] S. Chaplot, L.M. Patnaik, N.R. Jagannathan, "Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network", *Biomedical Signal Processing and Control*, vol. 1, no. 1, pp. 86-92, Jan. 2006 (doi: 10.1016/j.bspc.2006.05.002).
- [12] S.P. Rana, M. Dey, G. Tiberi, L. Sani, A. Vispa, G. Raspa, M. Duranti, M. Ghavami, S. Dudley, "Machine learning approaches for automated lesion detection in microwave breast imaging clinical data", *Scientific Reports*, vol. 9, Article Number: 10510, July. 2019 (doi: 10.1038/s41598-019-46974-3).

- [13] X. Wan, M. Qi, T. Chen, T.J. Cui, "Field-programmable beam reconfiguring based on digitally-controlled coding metasurface", *Scientific Reports*, vol. 6, pp. 1-8, Feb. 2016 (doi: 10.1038/srep20663).
- [14] A. Klautau, P. Batista, N. González-Prelcic, Y. Wang, R. W. Heath, "5G MIMO data for machine learning: application to beam-selection using deep learning", *Proceeding of the IEEE/ITA*, pp. 1-9, San Diego, CA, USA, Feb. 2018 (doi: 10.1109/ITA.2018.8503086).
- [15] L. Nanni, S. Ghidoni, S. Brahmam, "Handcrafted vs. non-handcrafted features for computer vision classification", *Pattern Recognition*, vol. 71, pp. 158-172, Nov. 2017 (doi: 10.1016/j.patcog.2017.05.025).
- [16] F. Hirtenfelder, "Effective antenna simulations using CST MICROWAVE STUDIO (R)", *Proceeding of the IEEE/INICA*, pp. 239-239, Munich, Germany, April. 2007 (doi: 10.1109/INICA.2007.4353972).
- [17] M. Ojaroudi, S. Bila, M. Salimi, "A novel approach of brain tumor detection using miniaturized high-fidelity UWB slot antenna array", *Proceeding of the IEEE/EuCAP*, pp. 1-5, Krakow, Poland, Mar./April 2019.
- [18] B.R. Lavoie, M. Okoniewski, E.C. Fear, "Estimating the effective permittivity for reconstructing accurate microwave-radar images", *Plos One*, vol. 11, no. 9, pp. 1-25, Sept. 2016 (doi: 10.1371/journal.pone.0160849).
- [19] R. Benny, T.A. Anjit, P. Mythili, "An overview of microwave imaging for breast tumor detection", *Progress in Electromagnetics Research*, vol. 87, pp. 61-91, May. 2020 (doi: 10.2528/PIERB20012402).
- [20] M.T. Islam, M.T. Islam, M. Samsuzzaman, S. Kibria, M.E.H Chowdhury, "Microwave breast imaging using compressed sensing approach of iteratively corrected delay multiply and sum beamforming", *Diagnostics*, vol. 11, no. 470, pp. 1-12, Mar. 2021 (doi: 10.3390/diagnostics11030470).
- [21] M.S. Islam, M.T. Islam, A. Hoque, M.T. Islam, N. Amin, M.E. Chowdhury, "A portable electromagnetic head imaging system using metamaterial loaded compact directional 3D antenna", *IEEE Access*, vol. 9, pp. 50893-50906, Mar. 2021 (doi: 10.1109/ACCESS.2021.3069712).
- [22] D.U.N. Qomariah, H. Tjandrasa, C. Fatichah, "Classification of diabetic retinopathy and normal retinal images using CNN and SVM", *Proceeding of the IEEE/ICTS*, pp. 152-157, Surabaya, Indonesia, July. 2019 (doi: 10.1109/ICTS.2019.8850940).
- [23] W. Shao, Y. Du, "Microwave imaging by deep learning network: Feasibility and training method", *IEEE Trans. on Antennas and Propagation*, vol. 68, pp. 5626-5635, July. 2020 (doi: 10.1109/TAP.2020.2978952).
- [24] M. Ghaffari, A. Sowmya, R. Oliver, "Automated brain tumor segmentation using multimodal brain scans: A survey based on models submitted to the BraTS 2012-2018 challenges", *IEEE Reviews in Biomedical Engineering*, vol. 68, pp. 5626-5635, Oct. 2019 (doi: 10.1109/RBME.2019.2946868).
- [25] A. Kerhet, M. Raffetto, A. Boni, A. Massa, "A SVM-based approach to microwave breast cancer detection", *Engineering Applications of Artificial Intelligence*, vol. 19, pp. 807-818, Oct. 2006 (doi: 10.1016/j.engappai.2006.05.010).
- [26] Y. Wu, M. Zhu, D. Li, Y. Zhang, Y. Wang, "Brain stroke localization by using microwave-based signal classification", *Proceeding of the IEEE/ICEAA*, pp. 828-831, Cairns, QLD, Australia, Sept. 2016 (doi: 10.1109/ICEAA.2016.7731527).
- [27] L. Guo, A. Abbosh, "Stroke localization and classification using microwave tomography with k-means clustering and support vector machine", *Bioelectromagnetics*, vol. 39, pp. 312-324, May. 2018 (doi: 10.1002/bem.22118).
- [28] M. Roohi, J. Mazloun, M.A. Pourmina, B. Ghalamkari, "Machine learning approaches for automated stroke detection, segmentation, and classification in microwave brain imaging systems", *Progress in Electromagnetics Research C*, vol. 116, pp. 193-205, Nov. 2021 (doi: 10.2528/PIERC21080404).

1. Microwave Imaging Systems (MIS)
2. Region of interest (ROI)
3. Back-projection (BP)
4. Intracervical hemorrhage classification
5. Ischemic stroke
6. Conventional neural network (CNN)
7. Support vector machine (SVM)
8. Delay-and-sum (DAS)
9. Delay-multiply-and-sum (DMAS)
10. Residual neural network (ResNet)
11. Artificial neural network (ANN)
12. Confusion matrix