



Islamic Azad University , Shiraz Branch  
Journal of Circuits, Data and Systems Analysis



**نشریه**

**تحلیل مدارها،**

**داده ها**

**و سامانه ها**





## نشریه تحلیل مدارها، داده ها و سامانه ها

### هیات تحریریه

مدیر مسئول	دکتر حامد آگاهی	دانشگاه آزاد اسلامی شیراز
سر دبیر	دکتر طاهر نیکنام	دانشگاه صنعتی شیراز
مدیر داخلی	دکتر زهرا مقصودزاده سروسستانی	دانشگاه آزاد اسلامی شیراز

### هیات تحریریه

استاد	دکتر طاهر نیکنام	دانشگاه صنعتی شیراز
استاد	دکتر رحیم غیور	دانشگاه شیراز
استاد	دکتر حبیب اله عبیری	دانشگاه شیراز
استاد	دکتر حمید خالوزاده	دانشگاه صنعتی خواجه نصیر
استاد	دکتر اصغر کشت کار	دانشگاه بین المللی امام خمینی
استاد	دکتر محمدباقر منهج	دانشگاه صنعتی امیرکبیر
استاد	دکتر محمد ناصر مقدسی	دانشگاه آزاد اسلامی واحد علوم و تحقیقات
استاد	دکتر حسن توکلی	دانشگاه علوم پزشکی بقیه الله
استاد	دکتر سید ابراهیم افجه ای	دانشگاه شهید بهشتی
دانشیار	دکتر حامد آگاهی	دانشگاه آزاد اسلامی شیراز
دانشیار	دکتر احمد فخاریان	دانشگاه آزاد اسلامی قزوین
دانشیار	دکتر امیرمسعود افتخاری مقدم	دانشگاه آزاد اسلامی قزوین
دانشیار	دکتر مجید ابن علی	دانشگاه شهرکرد
دانشیار	دکتر محمدصادق جوادی	دانشگاه آزاد اسلامی شیراز



## نشریه تحلیل مدارها، داده ها و سامانه ها

سال اول - شماره اول - بهار ۱۴۰۲

فهرست مقالات

ردیف	عنوان مقاله / نویسندگان	صفحه
۱	طبقه‌بندی بهینه تومورهای مغزی در تصاویر MRI به کمک یادگیری عمیق زهره عربی، امید مهدی‌یار، مهدی تقی زاده*	۱
۲	ناحیه‌بندی تصاویر مغز نوزادان بر اساس شبکه‌های عصبی پیچشی ایران سرافراز، حامد آگاهی*، آذر محمودزاده	۱۶
۳	تکنیک‌های تشخیص جعل کپی-جابجایی مبتنی بر روش‌های سنتی در تصاویر دیجیتال مریم عطائی قهفرخی، آذر محمودزاده*	۲۶
۴	مدل سلامت سیستم قدرت با حضور نیروگاه فتوولتاییک ایوب علیپور، امیر قاندى*، حمید کیوانی	۳۸
۵	الگوریتم‌های یادگیری عمیق در فرانتفیک‌پذیری تصاویر بهار قادری، حمید آزاد*	۴۷
۶	بهبود پایداری ریزشبکه‌ها با استفاده از کنترل کننده مود لغزشی تطبیقی مهدی متوسل	۵۷



## طبقه بندی بهینه تومورهای مغزی در تصاویر MRI به کمک یادگیری

### عمیق

زهره عربی<sup>۱</sup>، امید مهدی یار<sup>۲</sup>، مهدی تقی زاده<sup>\*۳</sup>

- ۱- دانشکده مهندسی برق- واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران  
 Arabi.zohre@gmail.com
- ۲- دانشکده مهندسی برق- واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران  
 M.taghizadeh@kau.ac.ir
- ۳- دانشکده مهندسی برق- واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران  
 Amir\_mahdiyar@yahoo.com

**چکیده:** فناوری های تصویربرداری پزشکی و بیولوژیک، اطلاعات تصویری ارزشمندی از ساختار و عملکرد یک ارگان را از سطح مولکول ها تا کل جسم فراهم می کنند. مغز پیچیده ترین عضو در بدن است و با توسعه سریع فناوری های تصویربرداری پزشکی و بیولوژیکی، توجهات تحقیقاتی فزاینده ای را به خود جلب می کند. از شایع ترین بیماری های مغز می توان به ایجاد بافت ناهنجار در سلول های مغزی اشاره کرد که منجر به تشکیل تومورهای مغزی می شود. از آنجایی که تومورهای مغزی با خطر مرگ و میر قابل توجهی مرتبط هستند و پیش بینی دقیق و سریع این بیماری در روند درمان تاثیر مستقیم دارد، لذا در این تحقیق از تعداد زیادی داده های تصویربرداری MRI تومور مغزی برای شناسایی سرطان های مغز و یافتن روشی با استفاده از تکنیک های یادگیری عمیق استفاده شد. برای تشخیص خودکار از چند مدل یادگیری عمیق استفاده شد و طبقه بندی سه نوع تومور مغزی، متشکل از گلیوم، مننژیوم و هیپوفیز نیز با این الگوریتم ها انجام شد. بر اساس نتایج آزمون های انجام شده، بهترین دقت نتایج به دست آمده در این تحقیق ۹۶ درصد بود که با در نظر گرفتن نسبت ۶۰ درصد برای داده های آموزشی و ۴۰ درصد برای داده های آزمون حاصل شد.<sup>□</sup>

**واژه های کلیدی:** تصویربرداری پزشکی، تومورهای مغزی، یادگیری عمیق، تصاویر MRI، گلیوم، مننژیوم، هیپوفیز

## Optimal Classification of Brain Tumors in MRI Images Using Deep Learning Techniques

Zohreh Arabi<sup>1</sup>, Omid Mahdiyar<sup>2</sup>, Mehdi Taghizadeh<sup>\*3</sup>

- <sup>1</sup> Department of Electrical Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
 Arabi.zohre@gmail.com
- <sup>2</sup> Department of Electrical Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
 M.taghizadeh@kau.ac.ir
- <sup>3</sup> Department of Electrical Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
 Amir\_mahdiyar@yahoo.com

### Abstract:

Medical and biological imaging technologies provide valuable image information of the structure and function of an organ from the level of molecules to the whole body. The brain is the most complex organ in the body and is attracting increasing research attention with the rapid development of medical and biological imaging technologies. One of the most common brain diseases is the creation of abnormal tissue in brain cells, which leads to the formation of brain tumors.

\*نویسنده مسئول؛ نشانی: ایران - کازرون - دانشگاه آزاد اسلامی کازرون - دانشکده مهندسی برق



Since brain tumors are associated with a significant risk of death and the accurate and rapid prediction of this disease has a direct impact on the treatment process, therefore, in this research, a large number of brain tumor MRI imaging data was used to identify brain cancers and find a method. Deep learning techniques were used. Several deep learning models were used for automatic diagnosis, and the classification of three types of brain tumors, consisting of glioma, meningioma, and pituitary, was also done with these algorithms. Based on the results of the conducted tests, the best accuracy of the results obtained in this research was 96%, which was obtained by considering the ratio of 60% for training data and 40% for test data.

**Keywords:** Medical Imaging, Brain tumors, Deep learning, glioma, meningioma, pituitary.

DOI: 00.00000/0000

تاریخ چاپ مقاله: ۱۴۰۲/۰۳/۲۱

تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۲۸

نوع مقاله: پژوهشی

تاریخ ارسال مقاله: ۱۴۰۲/۰۱/۱۵

می‌شود. تصویربرداری تشدید مغناطیسی متداول‌ترین فناوری مورد استفاده برای تشخیص سرطان مغز است و یکی از قدرتمندترین و پرکاربردترین روش‌های تصویربرداری در پزشکی بالینی است. عملکرد این فناوری به این صورت است که با استفاده از نیروی مغناطیسی قوی در اطراف اندام بیمار، از اعضای بدن بیمار عکس می‌گیرد.

در طول سه دهه گذشته، MRI پیشرفت‌های متعددی را به همراه داشته است که می‌تواند اطلاعات کمی و کاربردی مانند ریزمعماری شبکه و جریان پرفیوژن را ارائه دهد. MRI به دلیل توانایی این فناوری در عدم تهدید افراد آسیب پذیر، در مقایسه با سی تی اسکن، برای تشخیص تومورهای مغزی استفاده می‌شود. علاوه بر این، کیفیت تصاویر به دست آمده در حال پیشرفت بوده و تشخیص زود هنگام بیماری را تسهیل می‌کند. تصاویر MRI با سهولت بیشتری در اینترنت در دسترس است و در نتیجه محققانی که بر روی این موضوع تحقیق می‌کنند را تشویق به ایجاد محصولات برای کمک به کارکنان پزشکی می‌کند. فرآیند تشخیص توسط کادر پزشکی، تصمیم‌گیری و نتیجه‌گیری در مورد بیماران تومور مغزی به زمان زیادی نیاز دارد. در مقابل، درمان بیماران تومور مغزی نیاز به اقدام فوری دارد [۲].

با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق برای ایجاد سیستم‌های طبقه‌بندی، در فرآیند تشخیص با استفاده از تصاویر MRI، مدت زمان تشخیص کوتاه‌تر شده و نتیجه دقیق‌تری ارائه می‌شود. در سال‌های اخیر، مطالعات متعددی به طور خاص با هدف طبقه‌بندی تومورهای مغزی با استفاده از تصاویر MRI از بیماران انجام شده است. [۷،۵]. در پنج سال گذشته، مطالعات متعدد تأیید کردند که MRI می‌تواند بیماری تومور مغزی را با نتایج سریع‌تری طبقه‌بندی کند. [۸-۱۲]. مطالعه دیگری نشان داده است که دقت خوب در سناریوی اعمال شده به دو بخش شامل مدل‌های مختلف معماری برای مجموعه داده‌های مختلف تقسیم می‌شود. [۱۳-۱۸]. مطالعه‌ای توسط سلطان و همکاران [۶] جهت استفاده از الگوریتم CNN انجام شد. مجموعه داده مورد استفاده در سناریوی اول از مجموعه داده‌ای استفاده می‌کند که از بیمارستان نانفنگ و بیمارستان عمومی، دانشگاه پزشکی تیانجین، چین، از سال ۲۰۰۵ تا ۲۰۱۰ جمع‌آوری شده بود. تحقیق مرتبط بعدی توسط گوامی و همکاران [۷] انجام شد که تشخیص تومور مغزی را از مجموعه داده‌های تصویر MRI


## ۱- مقدمه

مغز به عنوان یک عضو مهم در بدن انسان مانند سایر اعضای بدن عمل می‌کند، اما می‌توان بیان نمود مغز نقش غلب در زندگی روزمره را ایفا می‌کند. مغز با اندازه ۱۳۵۰ سی سی بیش از ۱۰۰ میلیون سلول عصبی دارد که این سلول‌ها تمام فعالیت‌های انسان را کنترل می‌کنند. قشر مغز به بخش بیرونی مغز انسان اشاره دارد که عملکرد حسی را پردازش می‌کند، این قسمت از مغز فعالیت‌های حرکتی و شناختی سطح بالایی را تولید می‌کند [۱]. با توجه به مطالب بیان شده، مغز به یکی از مهم‌ترین اندام‌ها در حمایت از زندگی انسان تبدیل می‌شود. اگر مغز بمیرد، سلول‌های عصبی به درستی کار نمی‌کنند و منجر به مرگ بیمار می‌شود.

شایع‌ترین بیماری در مغز، تومور مغزی است که به دلیل رشد بافت غیرطبیعی در مغز ایجاد می‌شود. یکی از شایع‌ترین تومورهای مغزی در کودکان و بزرگسالان گلیوم یا آستروسیتوم است [۲]. بر اساس علت وقوع، بافت غیرطبیعی در مغز به دو نوع اولیه و ثانویه تقسیم می‌شود [۳]. تومور نوع اولیه مغزی به دلیل ایجاد سلول‌های توموری است که از خود بافت مغز منشأ می‌گیرند. به همین صورت، تومورهای مغزی‌ای که به عنوان تومور مغزی ثانویه طبقه‌بندی می‌شوند در نتیجه بافت سرطانی در سایر قسمت‌های بدن هستند که به مغز گسترش می‌یابد. تومورهای مغزی به دلیل جهش‌های ژنتیکی در سلول‌های مغز رشد می‌کنند، علی‌رغم اینکه در مورد جهش‌های ژنتیکی علت نامشخص است. با این حال، عوامل متعددی مانند سن، وراثت و رادیوتراپی وجود دارد که می‌تواند خطر ابتلا به تومور مغزی را افزایش دهد. در مجموع، کشنده‌ترین نوع تومور اولیه مغزی که معمولاً در بزرگسالان رخ می‌دهد، گلیوم است [۴-۵].

بر اساس داده‌های آژانس بین‌المللی تحقیقات سرطان در سال ۲۰۱۴، بیش از ۱۲۴۰۰۰ نفر از تومورهای مغزی رنج می‌برند که منجر به مرگ بیش از ۹۷۰۰۰ بیمار شده است که نشان می‌دهد این بیماری برای بقای فرد مبتلا خطرناک تلقی می‌شود. در این زمان، به دلیل دقت بالای فناوری فعلی و پیشرفت سریع آن، در اکثر تشخیص‌های بیماری، فناوری به‌عنوان یک پشتیبان برای معاینه توسط پزشک در نظر گرفته





شکل (۱): فلوچارت مدل تشخیص تومور

همانگونه که مشخص است در ابتدا الگوریتم جهت تشخیص تومور انتخاب می‌شود. پس از این مرحله تصاویر MRI موجود در الگوریتم جهت آموزش بارگزاری می‌شوند. پس از آموزش کامل، خروجی‌ها دسته‌بندی شده و عملکرد الگوریتم با توجه به نتایج آموزش و همچنین نتایج اعتبارسنجی مورد ارزیابی و مقایسه قرار می‌گیرد.

## ۲-۱- مجموعه داده تشخیص تومور

این مجموعه داده که در سایت Kaggle ارائه شده است به هدف کمک به افراد برای ساخت مدل‌های یادگیری ماشین جهت تشخیص تومورهای مغزی است. این مجموعه داده شامل اسکن MRI از مغز است. مجموعه داده به سه پوشه تقسیم می‌شود. (۱) yes- این پوشه حاوی ۱۵۰۰ عدد اسکن های MRI است که تومور دارند. (۲) no- این پوشه حاوی ۱۵۰۰ عدد اسکن های MRI است که تومور ندارند. (۳) pred- این پوشه حاوی ۶۰ عدد اسکن های MRI بدون برچسب برای اهداف آزمایشی است. در شکل (۲) تعدادی از تصاویر پوشه‌های yes و no که به صورت تصادفی انتخاب شده است ارائه می‌گردد.

ایجاد شده توسط چنگ انجام می‌داد، این مجموعه داده شامل ۳۰۶۴ تصویر MRI مغز بودند که به ۱۴۲۶ تصویر مننژیو، ۷۰۸ گلیوما و ۹۳۰ تصویر هیپوفیز تقسیم می‌شدند. روش ماشین یادگیری به شدت منظم شده<sup>۱</sup> مورد استفاده در این مطالعه به دقت ۹۲/۴۳ درصد منجر شد. سومین مطالعه با موضوع تومورهای مغزی در سال ۲۰۱۹ انجام شد که دقت بسیار بالایی نیز داشت، تحقیق انجام شده توسط دیپاک و همکاران [۸] ارائه گردید که با مدل CNN از پیش آموزش دیده دقت ۹۳ درصد را به دست آورد. در این تحقیق الگوریتم گوگل نت<sup>۲</sup> به عنوان روشی برای استخراج ویژگی از تصاویر MRI و ماشین بردار پشتیبان<sup>۳</sup> به عنوان روشی برای طبقه‌بندی تصاویر تومورهای مغزی استفاده شد. مجموعه داده مورد استفاده در این مطالعه از یک مجموعه داده ایجاد شده توسط چنگ که از فیگشیر<sup>۴</sup> به دست آمده استفاده کرد [۹]. تحقیقات انجام شده توسط سواتی و همکاران [۱۰] نیز از روش یادگیری انتقالی برای طبقه بندی تصاویر MRI از تومورهای مغزی استفاده کرد، روش VGG19، بهترین دقت ۹۲/۸۲٪ را به دست آورد. مجموعه داده مورد استفاده در این مطالعه از مجموعه داده‌ای با مجموع ۳۰۶۴ تصویر که از ۲۳۳ بیمار تومور مغزی به دست آمده بهره می‌برد [۹]. مطالعه مرتبط دیگری توسط نورین و همکاران [۱۱] انجام شد که از مجموعه داده‌های مرجع [۹] استفاده می‌نمود و شامل الگوریتم‌های InceptionV3 و DenseNet201 بود، که هر یک از الگوریتم‌ها به ترتیب دقت ۹۳/۹۴٪ و ۹۵/۱۱٪ را به دست آوردند. نتایج به دست آمده از چندین مطالعه قبلی نشان دهنده دقت روش‌ها بود. جهت ایجاد دقت بهتری نسبت به تحقیقات قبلی روشی که در آخرین تحقیقات بیان گردید، دقت بالای ۹۵٪ را ارائه نمود.

بر اساس مشکلات بیان شده، هدف نویسندگان این مقاله ایجاد مدلی است که بتواند تومورهای مغزی را با استفاده از تصاویر تشدید مغناطیسی (MRI) و از طریق استخراج ویژگی هر تصویر با استفاده از روش‌های یادگیری عمیق، تشخیص داده و طبقه‌بندی کند. لذا، در این مقاله یک کتابخانه منبع باز تنسورفلو ارائه می‌شود که مجموعه‌ای از الگوریتم‌های پایه و پیشرفته شامل الگوریتم‌های AlexNet، GoogLeNet، VGG15، VGG19 و ResNet50 را جهت تشخیص و طبقه بندی تصاویر MRI مغز اجرا نموده و در نهایت دقت هر یک از الگوریتم‌ها بررسی خواهد شد.

## ۲- داده‌ها و روش‌های به کار رفته

همانگونه که در بخش قبل بیان گردید هدف نهایی در این مقاله تشخیص و طبقه‌بندی تومورهای مغزی با استفاده از الگوریتم‌های شبکه‌های عصبی کانولوشنی است که در بخش‌های بعد به صورت جامع تشریح خواهند شد. جهت تشخیص وجود یا عدم وجود تومورهای مغزی مدلی طراحی شد که در شکل (۱) فلوچارت آن ارائه می‌شود.

<sup>۲</sup> SVM  
<sup>۴</sup> Figshare

<sup>۱</sup> RELM  
<sup>۲</sup> GoogleNet



## ۲-۲- مجموعه داده طبقه‌بندی تومور

این مجموعه داده ترکیبی از سه مجموعه داده زیر است:

- Figshare
- SARTAJ
- Br35H

این مجموعه داده شامل ۷۰۲۲ تصویر از تصاویر MRI مغز انسان است که به ۴ کلاس گلیوما - مننژیوم - بدون تومور و هیپوفیز طبقه‌بندی می‌شوند.

هیچ تصویر کلاس تومور از مجموعه داده Br35H گرفته نشد.


هیچ تصویر کلاس گلیوما از مجموعه داده SARTAJ گرفته نشد.

توزیع تصاویر در این مجموعه داده به صورت شکل (۳) می‌باشد و نمونه تصاویر در شکل (۴) ارائه شده است.

## ۲-۳- شبکه‌های عصبی کانولوشن

در این بخش، به طور خلاصه شبکه عصبی کانولوشن پایه (CNN) و انواع آن که اغلب در تجزیه و تحلیل تصاویر پزشکی استفاده می‌شود، ارائه می‌گردد. وظایفی که معمولاً توسط مدل‌های CNN در تصویربرداری پزشکی انجام می‌شود را می‌توان تقریباً به انجام سه وظیفه اصلی تقسیم کرد: طبقه‌بندی، تشخیص و تقسیم‌بندی. به عنوان مثال، مدل‌های معمولی مانند AlexNet, GoogleNet, VGG و ResNet با الحاق لایه‌های کاملاً متصل به طبقه‌بندی‌کننده‌های مختلف، هدف طبقه‌بندی را دارند. مدل‌هایی از جمله R-CNN, Faster RCNN و YOLO معمولاً برای تشخیص بیماری‌ها استفاده می‌شوند و مدل‌های دیگر مانند FCNN و U-Net به طور گسترده برای کار تقسیم‌بندی استفاده می‌شوند. همه مدل‌ها از بخش کانولوشن معماری‌های بنیادی CNN به عنوان استخراج‌کننده ویژگی استفاده می‌کنند (به عنوان مثال AlexNet, GoogleNet, VGG, ResNet) و لایه‌های کاملاً متصل را با تکنیک‌های دیگر برای کارهای خاص جایگزین می‌کنند.


یک شبکه عصبی کانولوشن از سه لایه تشکیل شده است - لایه ورودی، لایه پنهان و لایه خروجی، که شبیه به شبکه‌های عصبی سنتی مانند شبکه‌های عصبی مصنوعی (ANN) است. تفاوت بین CNN و ANN در لایه پنهان ارائه شده است. لایه پنهان یک مدل CNN معمولاً از سه لایه تشکیل شده است، یعنی لایه کانولوشن، لایه زیر نمونه (لایه ادغام) و لایه کاملاً متصل، همانطور که در شکل (۵) ارائه شده است.




شکل (۵): شبکه عصبی کانولوشن ساده



شکل (۲): تعدادی از تصاویر پوشه‌های yes و no که به صورت تصادفی انتخاب شده است.



شکل (۳): توزیع تصاویر در مجموعه داده طبقه‌بندی



شکل (۴): نمونه‌ای از تصاویر مجموعه داده و برچسب‌های آن



این شبکه در کل از ۲۲ لایه تشکیل شده است. معماری شبکه ارائه شده در این مقاله کاملاً با VGGNet، ZFNet و AlexNet متفاوت است. این الگوریتم شامل یک لایه کانولوشن  $1 \times 1$  در وسط شبکه است، و به جای استفاده از لایه‌های کاملاً متصل، از ادغام میانگین کل شبکه (میانگین جهانی) در انتهای شبکه استفاده می‌شود.

### ۲-۳-۳- بررسی الگوریتم VGG

شبکه VGG در دو معماری مختلف با عنوان‌های VGG 16 و VGG 19 ارائه شده است. ابتدا شبکه VGG 16 پیشنهاد شد و سپس با تغییراتی جزئی در شبکه VGG 16، شبکه VGG 19 مطرح گردید. شبکه VGG 16 همان‌طور که در شکل (۸) نشان داده شده، شامل ۱۶ لایه کانولوشنی یا ۱۶ لایه پارامتری است. شبکه VGG 16 شامل دو لایه کانولوشنی با  $64 \times 3 \times 3$  فیلتر  $3 \times 3$  هست که پشت سر هم قرار گرفته‌اند. سپس، یک لایه ماکس پولینگ  $2 \times 2$  با پرش به اندازه ۲ قرار گرفته است. این لایه ماکس پولینگ علاوه بر نمونه برداری، وظیفه کاهش بعد ویژگی‌ها به نصف را هم دارد. در ادامه، دو لایه کانولوشنی دیگر با  $128 \times 3 \times 3$  و یک لایه ماکس پولینگ  $2 \times 2$  با پرش ۲ قرار گرفته‌اند. به‌طور مشابه، سه لایه کانولوشنی با  $256 \times 3 \times 3$  فیلتر  $3 \times 3$  و یک لایه ماکس پولینگ  $2 \times 2$  با پرش ۲ قرار گرفته‌اند. ۳ لایه کانولوشنی با  $512 \times 3 \times 3$  فیلتر  $3 \times 3$  و یک لایه ماکس پولینگ ادامه این شبکه هست که البته دو بار تکرار می‌شود. در نهایت، ویژگی‌ها تبدیل به یک بردار ویژگی می‌شوند تا در اختیار لایه‌های نورونی یا تمام‌اتصال قرار گیرند. دو لایه نورونی به ابعاد  $4096$  پشت سر هم قرار گرفته‌اند. در نهایت، یک لایه نورونی به ابعاد  $1000$  که متناظر با تعداد کلاس‌های کاربردی ما هست، در نظر گرفته شده است.

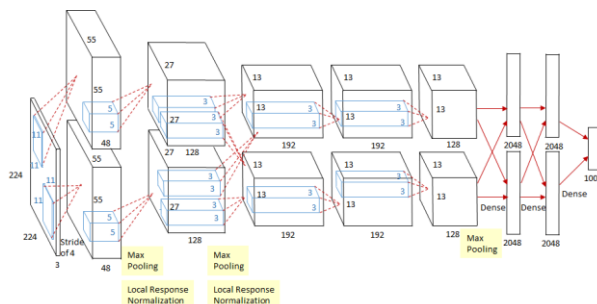
### ۲-۳-۴- بررسی الگوریتم ResNet

این الگوریتم تلاش می‌کند تا فرآیند یادگیری را برای الگوریتم‌های بهینه‌سازی ساده‌تر کند و عمق شبکه عصبی را به هر میزان که خواهد زیاد کند. پیشنهاد شد که وقتی شبکه نمی‌تواند به صورت مستقیم لایه هویت را یاد بگیرد به کمک یک مسیر جایگزین به او در این زمینه کمک شود. شکل (۹) این موضوع را نشان می‌دهد. همان‌طور که در این شکل نشان داده شده است علاوه بر مسیر اصلی که شامل لایه‌های کانولوشنی، عادی‌سازی دسته‌ای و تابع فعال‌سازی است، داده ورودی به صورت مستقیم و بدون هیچ تغییری با خروجی لایه‌های غیرخطی استفاده شده جمع می‌گردد.


### ۳- نتایج

بخش نتایج به دو قسمت تقسیم می‌شود:


- ✓ تشخیص تومور توسط الگوریتم‌ها
- ✓ طبقه‌بندی داده‌های MRI توسط الگوریتم‌ها




شکل (۶): معماری شبکه AlexNet



شکل (۷): معماری شبکه GoogleNet



شکل (۸): معماری شبکه VGG16



شکل (۹): استفاده از مسیر جایگزین

### ۲-۳-۱- بررسی الگوریتم AlexNet

الگوریتم AlexNet یک شبکه عصبی کانولوشنی عمیق است که به‌منظور شناسایی و طبقه‌بندی تصاویر رنگی با سایز  $224 \times 224 \times 3$  با ساختار شکل (۶) ارائه شده است. به‌طور کلی این شبکه‌ی عصبی  $62$  میلیون پارامتر یادگیری و  $11$  لایه دارد.

### ۲-۳-۲- بررسی الگوریتم GoogleNet

از نام "GoogLeNet" به وضوح مشخص است که ارائه دهنده این الگوریتم Google است. و همچنین "GoogLeNet" حاوی کلمه "LeNet" برای ادای احترام به الگوریتم LeNet پروفیسور یان لیکن است. به این الگوریتم Inception v1 نیز می‌گویند زیرا نسخه‌های ۲، ۳ و ۴ نیز وجود دارند (شکل (۷)).





### ۳-۱-۳- فراخوانی (حساسیت)

یکی از مهمترین پارامترهای ارزیابی، پارامتر فراخوانی است که به آن «نرخ پاسخ‌های مثبت درست» نیز می‌گویند. تمرکز اصلی معیار فراخوانی بر خلاف معیار صحت (که نتایج مثبت کاذب را نیز بررسی می‌نمود) بر روی داده‌هایی است که واقعاً «مثبت» بوده‌اند. فراخوانی به معنی نسبتی از موارد مثبت صحیح به کل نتایج مثبت (مجموع مثبت صحیح و منفی کاذب) موجود است. این پارامتر به صورت زیر محاسبه می‌شود:

$$Recall = Sensivity = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (۳)$$

### ۳-۱-۴- معیار تشخیص‌پذیری

از متداول‌ترین پارامترها که معمولاً در کنار فراخوانی بررسی می‌شود، پارامتر خاصیت تشخیص‌پذیری است که به آن «نرخ پاسخ‌های منفی درست» نیز می‌گویند. این خاصیت به معنی نسبتی از موارد منفی است که آزمایش آن‌ها را به درستی به عنوان نمونه منفی تشخیص داده است. این پارامتر به صورت زیر محاسبه می‌شود:

$$Specificity = \frac{N_{TN}}{N_{TN} + N_{FP}} \quad (۴)$$

### ۳-۱-۵- معیارهای ارزیابی امتیاز F1 یا F-measure

یکی از بهترین معیارها برای بررسی دقت یک مدل معیار امتیاز F1 است. این معیار صحت و فراخوانی را با هم در نظر می‌گیرد. معیار F1 در بهترین حالت، یک و در بدترین حالت صفر است.

$$F - measure = \frac{2 \times (recall \times Percision)}{recall + Percision} \quad (۵)$$

### ۳-۱-۶- مساحت زیر نمودار منحنی مشخصه عملکرد

#### سیستم<sup>۱</sup>

یکی از روش‌های بررسی و ارزیابی عملکرد دسته‌بندی دو دویی، «نمودار مشخصه عملکرد» است. کارایی الگوریتم‌های «دسته‌بندی دو دویی» معمولاً به وسیله شاخص‌هایی مثل «فراخوانی» و «تشخیص‌پذیری» سنجیده می‌شوند. اما در نمودار مشخصه عملکرد هر دوی این شاخص‌ها ترکیب شده و به صورت یک منحنی نمایش داده می‌شوند. اغلب برای بررسی کارایی الگوریتم‌های دسته‌بندی یا ایجاد داده‌های رسته‌ای از منحنی مشخصه عملکرد استفاده می‌کنند. معیار ارزیابی مساحت زیر نمودار منحنی مشخصه عملکرد سیستم اطلاعاتی را در مورد اینکه یک مدل کار خود در جداسازی موارد را به خوبی انجام می‌دهد ارائه می‌دهد.

در هر دو قسمت شبیه‌سازی‌ها برای الگوریتم‌های تشریح شده ارائه شد. اما برای بررسی عملکرد الگوریتم‌ها نیاز به تعریف شاخص‌های عملکردی است که در ادامه ارائه خواهد شد.

### ۳-۱-۱- معیارهای ارزیابی الگوریتم‌های هوش مصنوعی

جهت بررسی کیفیت عملکرد الگوریتم‌های مختلف، معیارهای ارزیابی تعریف می‌شوند. این معیارها کارایی الگوریتم را برای موارد استفاده مختلف تفسیر و توصیف می‌نمایند. در ارزیابی نتایج معمولاً معیارهای زیر متصور است و بیشترین استفاده را نسبت به معیارهای ارزیابی دیگر دارد.

- ✓ معیار ارزیابی دقت
- ✓ معیار ارزیابی صحت
- ✓ معیار ارزیابی فراخوانی
- ✓ معیار ارزیابی تشخیص‌پذیری
- ✓ معیار ارزیابی امتیاز F1
- ✓ معیار ارزیابی مساحت زیر نمودار منحنی عملکرد سیستم
- ✓ معیار ارزیابی MCC

### ۳-۱-۱-۱- معیار ارزیابی دقت

برای بررسی میزان درست بودن نتایج خروجی پارامتر دقت تعریف می‌شود. با بررسی این پارامتر می‌توان به صورت کلی کارایی مدل را بررسی نمود. به علاوه این پارامتر، بیانگر چگونگی آموزش مدل است. نکته مهمی که درباره این معیار می‌توان بیان نمود عدم ارائه اطلاعات جزئی در مورد کارایی مدل بوده و فقط حد آموزش یافتن مدل را نشان می‌دهد. این پارامتر از تقسیم مجموع نتایج مثبت و منفی پیش‌بینی شده صحیح تقسیم بر تعداد کل نتایج که شامل نتایج مثبت و منفی صحیح و غلط است به دست می‌آید.

$$Accuracy = \frac{N_{TN} + N_{TP}}{N_{TN} + N_{FN} + N_{TP} + N_{FP}} \quad (۱)$$

### ۳-۱-۲- صحت

جهت ارزیابی نتایج مثبت مدل، معیار صحت مورد بررسی قرار می‌گیرد. در واقع این معیار بیان می‌نماید چند درصد جواب‌های مثبت الگوریتم درست است. برای محاسبه این معیار، نسبت نتایج موارد صحیح طبقه‌بندی‌شده توسط الگوریتم به کل تعداد مواردی که الگوریتم چه به‌صورت صحیح و چه به‌صورت غلط، در آن کلاس مثبت طبقه‌بندی کرده است تقسیم می‌شود:

$$Precision = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (۲)$$



### ۳-۱-۷- معیار ارزیابی MCC<sup>۱</sup>

را در مجموعه آموزشی ارزیابی می کند. قابل ذکر است که مجموعه آموزشی بخشی از مجموعه داده است که برای آموزش اولیه مدل استفاده می شود. ضریب زیان اعتبارسنجی میزان خطای مدل بر روی داده های دیده نشده را بیان می نماید. از نظر محاسباتی، ضریب زیان آموزش با در نظر گرفتن مجموع خطاها برای هر مثال در مجموعه آموزشی محاسبه می شود. هر بار که یک مجموعه داده از یک الگوریتم عبور می کند، گفته می شود که یک آپک<sup>۲</sup> را به پایان رسانده است. بنابراین، آپک در یادگیری ماشین، به انتقال کل داده های آموزشی از طریق الگوریتم اشاره دارد. آپک یک فراپارامتر است که روند آموزش مدل یادگیری ماشین را تعیین می کند.

همانگونه که در شکل (۱۰) مشخص است، ضریب زیان الگوریتم AlexNet در مرحله آموزش کمتر از ۰/۱۱ درصد و در مرحله اعتبارسنجی تقریباً برابر ۰/۰۹ درصد است. ضریب دقت در الگوریتم AlexNet در مرحله آموزش تقریباً ۹۸ درصد و در مرحله اعتبارسنجی تقریباً ۹۹ درصد است. این نتایج بیانگر آن است که در مرحله آموزش، خطای مشاهده شده پس از ۱۲۰ تکرار آموزش ۰/۱۱ درصد است و پس از آموزش الگوریتم، خطای مشاهده شده برای مجموعه داده های اعتبارسنجی ۰/۰۹ کاهش می یابد. به علاوه ضریب دقت که بیانگر تشخیص صحیح الگوریتم پس از ۱۲۰ بار تکرار آموزش است برابر ۹۸ درصد است و برای اعتبارسنجی الگوریتم پس از آموزش، ضریب دقت یا به عبارتی دیگر تشخیص صحیح توسط الگوریتم ۹۹ درصد است.

در ادامه ماتریس درهم ریختگی برای سه مرحله آموزش، آزمایش و اعتبارسنجی ارائه می شود (شکل ۱۱). همانگونه که در قسمت قبل بیان شد ماتریس درهم ریختگی بیانگر تعداد تشخیص صحیح مثبت یا منفی و همچنین تشخیص کاذب مثبت و یا منفی است. در قطر اصلی نتایج صحیح مثبت و منفی مشخص می شوند. در این مقاله، سطر اول تعداد منفی ها صحیح و کاذب ارائه می شود و در سطر دوم منفی کاذب و صحیح بیان خواهد شد. مجموعه داده ۳۰۰۰ عکس MRI تومورهای مغزی با توجه به قرار گرفتن ۶۰ درصد این عکس ها در مجموعه داده آموزش و ۴۰ درصد در مجموعه داده اعتبارسنجی به صورت ذیل بررسی خواهد شد. تعداد ۱۸۰۰ عکس به صورت تصادفی از مجموعه برای آموزش انتخاب می شوند. ۹۰۰ عکس دارای تومور و ۹۰۰ عکس فاقد تومور است. جهت بررسی عملکرد الگوریتم آموزش یافته، دو مجموعه اعتبارسنجی و آزمایش هر دو با تعداد ۶۰۰ عکس ایجاد می شود. ۳۰۰ عکس دارای تومور و ۳۰۰ عکس فاقد تومور است. در مرحله آموزش پس از ۱۲۰ تکرار، الگوریتم ۸۹۳ عکس از تصاویر بدون تومور را صحیح تشخیص می دهد، اما ۷ عدد از این تصاویر را مثبت کاذب تشخیص می دهد. در مورد تصاویر با تومور، الگوریتم ۳ عدد از تصاویر را منفی کاذب تشخیص داده و ۸۹۷ عدد را به درستی با تومور تشخیص می دهد. همچنین، در مرحله اعتبارسنجی تعداد صحیح منفی ۲۹۷ و تعداد صحیح مثبت ۲۹۹ است و تعداد منفی کاذب ۳ و تعداد مثبت کاذب ۱ تصویر است.

epoch<sup>۲</sup>

پارامتر دیگری که برای ارزیابی کارایی الگوریتم های یادگیری ماشین از آن استفاده می شود معیار ارزیابی MCC است. این پارامتر بیانگر کیفیت کلاس بندی برای یک مجموعه باینری است. و سنجای است که بیانگر بستگی مابین مقادیر مشاهده شده از کلاس باینری و مقادیر پیش بینی شده از آن می باشد. مقادیر مورد انتظار برای این کمیت در بازه ۱- و ۱ متغیر می باشد. مقدار +۱، نشان دهنده پیش بینی دقیق و بدون خطای الگوریتم یادگیر از کلاس باینری می باشد. مقدار ۰، نشان دهنده پیش بینی تصادفی الگوریتم یادگیر از کلاس باینری می باشد. مقدار -۱، نشان دهنده عدم تطابق کامل مابین موارد پیش بینی شده از کلاس باینری و موارد مشاهده شده از آن می باشد. مقدار این پارامتر را به طور صریح، با توجه به مقادیر ماتریس آشفستگی به شرح زیر، می توان محاسبه نمود:

$$MCC = \frac{N_{TP} \times N_{TN} - N_{FP} \times N_{FN}}{\sqrt{(N_{TP} + N_{FP})(N_{TP} + N_{FN})(N_{TN} + N_{FP})(N_{TN} + N_{FN})}} \quad (۶)$$

### ۳-۱-۸- ماتریس درهم ریختگی

در حوزه هوش مصنوعی، ماتریس درهم ریختگی به ماتریسی گفته می شود که در آن عملکرد الگوریتم های مربوطه را نشان می دهند. معمولاً چنین نمایشی برای الگوریتم های یادگیری با ناظر استفاده می شود، اگرچه در یادگیری بدون ناظر نیز کاربرد دارد. معمولاً به کاربرد این ماتریس در الگوریتم های بدون ناظر ماتریس تطابق می گویند. هر ستون از ماتریس، نمونه ای از مقدار پیش بینی شده را نشان می دهد. در صورتی که هر سطر نمونه ای واقعی (درست) را در بر دارد. اسم این ماتریس نیز از آنجا به دست می آید که امکان این را فراهم می نماید که آسان تر اشتباه و تداخل بین نتایج را مشاهده کرد. خارج از حوزه هوش مصنوعی، این ماتریس معمولاً ماتریس پیشابندی یا ماتریس خطا نامیده می شود.

### ۳-۲- تشخیص تومور توسط الگوریتم ها

جهت تشخیص تومور از الگوریتم های AlexNet، GoogleNet، VGG19، VGG16 و ResNet50 استفاده شد.

### ۳-۲-۱- نتایج الگوریتم AlexNet

جهت بررسی عملکرد الگوریتم ضرایب دقت و زیان تعریف می شوند. پس از توضیحاتی پیرامون این ضرایب، نتایج الگوریتم AlexNet مورد بررسی قرار خواهد گرفت. ضریب دقت و زیان معیارهایی برای ارزیابی چگونگی مطابقت یک مدل یادگیری عمیق با داده های مورد بررسی است. ضریب دقت آموزش، بررسی عملکرد مدل بر روی داده هایی است که با آن ها آموزش دیده است، در حالی که ضریب دقت اعتبارسنجی میزان عملکرد مدل بر روی داده های دیده نشده است. ضریب زیان آموزش، خطای مدل

Matthew's correlation coefficient<sup>۱</sup>



در مرحله آزمایش نیز تعداد صحیح منفی ۲۹۷ و تعداد صحیح مثبت ۲۸۹ تصویر است. در این حالت تعداد منفی کاذب ۳ و تعداد مثبت کاذب ۱۱ عدد توسط الگوریتم تشخیص داده شده است.



### ۲-۲-۳- نتایج الگوریتم GoogleNet

ضریب زیان الگوریتم GoogleNet در مرحله آموزش کمتر از ۰/۵ درصد و در مرحله اعتبارسنجی تقریباً برابر ۶ درصد است. ضریب دقت در الگوریتم GoogleNet در مرحله آموزش تقریباً ۹۳ درصد و در مرحله اعتبارسنجی تقریباً ۶۵ درصد است. این نتایج بیانگر آن است که در مرحله آموزش خطای مشاهده شده پس از ۱۲۰ تکرار روند آموزش مدل، ۰/۵ درصد است و پس از آموزش الگوریتم، خطای مشاهده شده برای مجموعه داده‌های اعتبارسنجی مقدار ۶ درصد خواهد بود. به علاوه ضریب دقت که بیانگر تشخیص صحیح الگوریتم پس از ۱۲۰ بار تکرار آموزش است برابر ۹۸ درصد است و برای اعتبارسنجی الگوریتم پس از آموزش، ضریب دقت یا به عبارتی دیگر تشخیص صحیح توسط الگوریتم ۹۹ درصد است (شکل ۱۲).


در ادامه ماتریس درهم ریختگی برای سه مرحله آموزش، آزمایش و اعتبارسنجی ارائه می‌شود. در مرحله آموزش پس از ۱۲۰ تکرار، الگوریتم ۷۵۱ عکس از تصاویر بدون تومور را صحیح تشخیص می‌دهد، اما ۶۵ عدد از این تصاویر را مثبت کاذب تشخیص می‌دهد. در مورد تصاویر با تومور، الگوریتم ۱۳۴ عدد از تصاویر را منفی کاذب تشخیص داده و ۷۶۶ عدد را به درستی با تومور تشخیص می‌دهد. در مرحله اعتبارسنجی تعداد صحیح منفی ۲۴۸ و تعداد صحیح مثبت ۲۵۰ است و تعداد منفی کاذب ۵۲ و تعداد مثبت کاذب ۵۰ تصویر است. در مرحله آزمایش نیز تعداد صحیح منفی ۲۳۵ و تعداد صحیح مثبت ۲۴۷ تصویر است. در این حالت تعداد منفی کاذب ۶۵ و تعداد مثبت کاذب ۵۳ عدد توسط الگوریتم تشخیص داده شده است (شکل ۱۳).

### ۳-۲-۳- نتایج الگوریتم VGG16

ضریب زیان الگوریتم VGG16 در مرحله آموزش کمتر از ۰/۴۵ درصد و در مرحله اعتبارسنجی تقریباً برابر ۵/۸ درصد است. ضریب دقت در الگوریتم VGG16 در مرحله آموزش تقریباً ۹۸ درصد و در مرحله اعتبارسنجی تقریباً ۹۳ درصد است. این نتایج بیانگر آن است که در مرحله آموزش خطای مشاهده شده پس از ۱۲۰ تکرار روند آموزش مدل، ۰/۴۵ درصد است و پس از آموزش الگوریتم، خطای مشاهده شده برای مجموعه داده‌های اعتبارسنجی مقدار ۵/۸ درصد خواهد بود. به علاوه ضریب دقت که بیانگر تشخیص صحیح الگوریتم پس از ۱۲۰ بار تکرار آموزش است برابر ۹۸ درصد است و برای اعتبارسنجی الگوریتم پس از آموزش، ضریب دقت یا به عبارتی دیگر تشخیص صحیح توسط الگوریتم ۹۳ درصد است (شکل ۱۴).




شکل (۱۰): ضریب زیان و دقت الگوریتم AlexNet




شکل (۱۱): ماتریس درهم ریختگی الگوریتم AlexNet برای سه مرحله آموزش، آزمایش، اعتبارسنجی




Training Loss and Accuracy on Brain Tumor Classification




Training Loss and Accuracy on Brain Tumor Classification



Training Loss and Accuracy on Brain Tumor Classification





Training Loss and Accuracy on Brain Tumor Classification



شکل (۱۴): ضریب زبان و دقت الگوریتم VGG16

شکل (۱۲): ضریب زبان و دقت الگوریتم GoogleNet




شکل (۱۵): ماتریس در هم ریختگی الگوریتم VGG16 برای سه مرحله آموزش، آزمایش، اعتبارسنجی

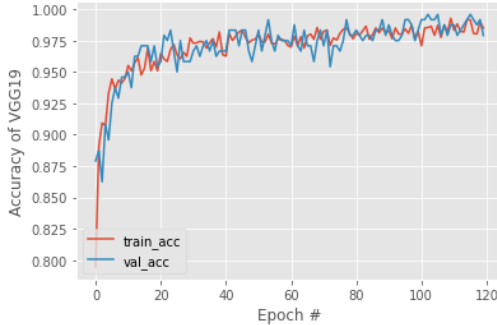
شکل (۱۳): ماتریس در هم ریختگی الگوریتم GoogleNet برای سه مرحله آموزش، آزمایش، اعتبارسنجی




Training Loss and Accuracy on Brain Tumor Classification



Training Loss and Accuracy on Brain Tumor Classification



شکل (۱۶): ضریب زیان و دقت الگوریتم VGG19



شکل (۱۷): ماتریس درهم ریختگی الگوریتم VGG19 برای سه مرحله آموزش، آزمایش، اعتبارسنجی

در ادامه ماتریس درهم ریختگی برای سه مرحله آموزش، آزمایش و اعتبارسنجی ارائه می‌شود. در مرحله آموزش پس از ۱۲۰ تکرار، الگوریتم ۸۹۹ عکس از تصاویر بدون تومور را صحیح تشخیص می‌دهد، اما ۱ عدد از این تصاویر را مثبت کاذب تشخیص می‌دهد. در مورد تصاویر با تومور، الگوریتم ۲ عدد از تصاویر را منفی کاذب تشخیص داده و ۸۹۸ عدد را به درستی با تومور تشخیص می‌دهد. در مرحله اعتبارسنجی تعداد صحیح منفی ۲۹۷ و تعداد صحیح مثبت ۲۹۷ است و تعداد منفی کاذب ۳ و تعداد مثبت کاذب ۳ تصویر است. در مرحله آزمایش نیز تعداد صحیح منفی ۲۹۷ و تعداد صحیح مثبت ۲۹۹ تصویر است. در این حالت تعداد منفی کاذب ۳ و تعداد مثبت کاذب ۱ عدد توسط الگوریتم تشخیص داده شده است (شکل ۱۵).

### ۴-۲-۳- نتایج الگوریتم VGG19

ضریب زیان الگوریتم VGG19 در مرحله آموزش کمتر از ۰/۰۵ درصد و در مرحله اعتبارسنجی تقریباً برابر ۰/۰۸ درصد است. ضریب دقت الگوریتم VGG19 تقریباً برابر ۹۸/۳ درصد است. این نتایج بیانگر آن است که در مرحله آموزش، خطا پس از ۱۲۰ تکرار روند آموزش مدل، ۰/۰۵ درصد است و پس از آموزش الگوریتم، خطا برای مجموعه داده‌های اعتبارسنجی مقدار ۰/۰۸ درصد خواهد بود. به علاوه، ضریب دقت برابر ۹۸/۳ درصد است و برای اعتبارسنجی الگوریتم پس از آموزش، ضریب تشخیص صحیح توسط الگوریتم ۹۸ درصد است (شکل ۱۶).

در ادامه ماتریس درهم ریختگی ارائه می‌شود. در مرحله آموزش پس از ۱۲۰ تکرار، الگوریتم ۸۹۴ عکس از تصاویر بدون تومور را صحیح تشخیص می‌دهد، اما ۶ عدد را مثبت کاذب تشخیص می‌دهد. در مورد تصاویر با تومور، الگوریتم ۲ تصویر را منفی کاذب تشخیص داده و ۸۹۸ عدد را به درستی با تومور تشخیص می‌دهد. در مرحله اعتبارسنجی، تعداد صحیح منفی ۲۹۶، تعداد صحیح مثبت ۲۹۵، تعداد منفی کاذب ۴ و تعداد مثبت کاذب ۵ تصویر است. در مرحله آزمایش نیز تعداد صحیح منفی ۲۹۶، تعداد صحیح مثبت ۲۹۷، منفی کاذب ۴ و مثبت کاذب ۳ عدد توسط الگوریتم تشخیص داده شده است (شکل ۱۷).

### ۵-۲-۳- نتایج الگوریتم ResNet50

ضریب زیان الگوریتم ResNet50 در مرحله آموزش کمتر از ۰/۱ درصد و در مرحله اعتبارسنجی تقریباً برابر ۲ درصد است. ضریب دقت الگوریتم ResNet50 در مرحله آموزش تقریباً ۹۹ درصد و در مرحله اعتبارسنجی تقریباً ۸۳ درصد است. این نتایج بیانگر آن است که در مرحله آموزش، خطای آموزش مدل، ۰/۰۱ درصد است و پس از آموزش الگوریتم، خطای مشاهده شده برای مجموعه داده‌های اعتبارسنجی مقدار ۲ درصد خواهد بود. به علاوه، ضریب دقت که بیانگر تشخیص صحیح الگوریتم پس از ۱۲۰ بار تکرار آموزش است برابر ۹۹ درصد است و برای اعتبارسنجی الگوریتم پس از آموزش، ضریب دقت یا به عبارتی دیگر تشخیص صحیح توسط الگوریتم ۸۳ درصد است.



در ادامه ماتریس درهم ریختگی برای سه مرحله آموزش، آزمایش و اعتبارسنجی ارائه می‌شود. در مرحله آموزش پس از ۱۲۰ تکرار، الگوریتم ۸۹۹ عکس از تصاویر بدون تومور را صحیح تشخیص می‌دهد، اما ۱ عدد از این تصاویر را مثبت کاذب تشخیص می‌دهد. در مورد تصاویر با تومور، الگوریتم ۱ عدد از تصاویر را منفی کاذب تشخیص داده و ۸۹۹ عدد را به درستی با تومور تشخیص می‌دهد. در مرحله اعتبارسنجی تعداد صحیح منفی ۲۹۹ و تعداد صحیح مثبت ۲۹۷ است و تعداد منفی کاذب ۱ و تعداد مثبت کاذب ۳ تصویر است. در مرحله آزمایش نیز، تعداد صحیح منفی ۲۹۷ و تعداد صحیح مثبت ۲۹۹ تصویر است. در این حالت تعداد منفی کاذب ۳ و تعداد مثبت کاذب ۱ عدد توسط الگوریتم تشخیص داده شده است.

### ۳-۲-۶- عملکرد الگوریتم‌های تشخیص تومورهای مغزی

نتایج حاصل از به کارگیری الگوریتم‌های AlexNet، GoogLeNet، VGG16، VGG19 و ResNet50 برای مجموعه داده‌های در نظر گرفته شده در این مقاله، در جدول (۱) ارائه شده است. همانگونه که مشخص است در بین الگوریتم‌ها، نتایج بیانگر دقت بالای الگوریتم‌های VGG16 و ResNet50 در تشخیص تومور در تصاویر MRI می‌باشد. هرچند می‌توان با در نظر گرفتن معیار مقدار مساحت زیر نمودار منحنی مشخصه عملکرد سیستم، بیان نمود الگوریتم VGG16 دقت بالاتری نسبت به سایر الگوریتم‌ها دارد. علاوه بر این، کمترین دقت در بین الگوریتم‌های ارائه شده مربوط به الگوریتم GoogleNet است. می‌توان علت نتایج را به معماری الگوریتم‌ها نسبت داد که با توجه به وجود ۱۶ لایه کانولوشن در الگوریتم VGG16 یکی از دقیق‌ترین الگوریتم‌هاست. الگوریتم ResNet50 نیز به واسطه استفاده از ۱۵۲ لایه و تکنیک "اتصالات پرش" یکی از سریع‌ترین و دقیق‌ترین الگوریتم‌هاست.


### ۳-۳- طبقه‌بندی داده‌های MRI

در طبقه‌بندی، کد نوشته شده علاوه بر این که باید تشخیص دهد این تصویر دارای تومور است نوع تومور را نیز باید مشخص نماید. جهت انجام طبقه‌بندی نیاز به مجموعه داده‌ای است که دارای انواع مختلف تومور بوده و برچسب هر تصویر، نوع تومور را مشخص نماید. با توجه به توضیحات بیان شده مجموعه داده پیشین ناقص است و باید با مجموعه داده دوم جایگزین شود. در ادامه عملکرد الگوریتم‌های مختلف در طبقه‌بندی تصاویر مورد بررسی قرار خواهد گرفت.

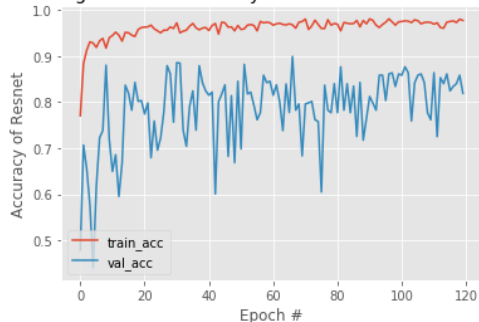
جدول (۱): عملکرد الگوریتم‌ها

ROC AUC	F1 Score	Specificity %	Precision %	Accuracy %	الگوریتم
99.67	97.67	97.67	97.77	97.67	AlexNet
88.29	80.32	80.33	80.38	80.33	GoogLeNet
99.98	99.33	99.33	99.34	99.33	VGG16
99.2	98.83	98.83	9.83	98.83	VGG19
99.86	99.33	99.33	99.34	99.33	ResNet50


Training Loss and Accuracy on Brain Tumor Classification



Training Loss and Accuracy on Brain Tumor Classification



شکل (۱۸): ضریب زیان و دقت الگوریتم ResNet50




شکل (۱۹): ماتریس درهم ریختگی الگوریتم ResNet50 برای سه

مرحله آموزش، آزمایش، اعتبارسنجی




### ۱-۳-۳- طبقه‌بندی مجموعه داده به کمک الگوریتم

#### AlexNet




شکل (۲۰): نمودارهای عملکردی الگوریتم AlexNet



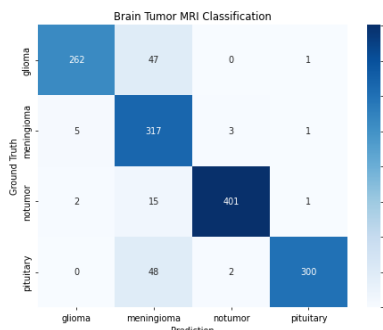
شکل (۲۱): ماتریس در هم‌ریختگی الگوریتم AlexNet

### ۲-۳-۳- طبقه‌بندی مجموعه داده به کمک الگوریتم

#### GoogLeNet



شکل (۲۲): نمودارهای عملکردی الگوریتم GoogLeNet



شکل (۲۳): ماتریس در هم‌ریختگی الگوریتم GoogLeNet

نمودارهای عملکردی الگوریتم GoogLeNet. دقت در فاز آموزش را تقریباً ۹۷ درصد و در دقت در فاز اعتبارسنجی را ۹۰ درصد بیان می‌نماید، خطا نیز در فاز آموزش تقریباً ۰/۱ درصد و در فاز اعتبارسنجی ۱/۳۸ درصد است. در ماتریس درهم ریختگی مشخص است این الگوریتم با تشخیص صحیح تعداد ۴۰۱ تصویر بدون تومور از تعداد ۴۱۹ تصویر بدون تومور بهترین عملکرد را در طبقه‌بندی تصاویر بدون تومور داشته است. به همین ترتیب دقت طبقه‌بندی‌ها در هیپوفیز بالاتر از مننژیوم و در مننژیوم بالاتر از گلیوما است. دقت کلی الگوریتم در طبقه‌بندی تصاویر تومورهای مغزی نیز ۹۱ درصد است.

### ۳-۳-۳- طبقه‌بندی مجموعه داده به کمک الگوریتم

#### VGG16

نمودارهای عملکردی الگوریتم VGG16. دقت در فاز آموزش را تقریباً ۹۹ درصد و در دقت در فاز اعتبارسنجی را ۹۵ درصد بیان می‌نماید، خطا نیز در فاز آموزش تقریباً ۰/۰۱ درصد و در فاز اعتبارسنجی ۰/۱ درصد است. جدول شاخص‌های عملکردی الگوریتم VGG16 برای هر چهار کلاس طبقه‌بندی که به ترتیب گلیوما، مننژیوم، تصاویر بدون تومور و هیپوفیز است، بیانگر دقت بالای الگوریتم در تشخیص کلاس تصاویر بدون تومور و تومورهای هیپوفیز و دقت پایین‌تر الگوریتم در تشخیص تصاویر تومورهای مننژیوم است. دقت کلی الگوریتم در طبقه‌بندی تصاویر تومورهای مغزی نیز ۹۶ درصد است.

جدول (۲): عملکرد الگوریتم AlexNet

F1 Score	Specificity %	Precision %	کلاس
92	97	88	گلیوما
88	84	93	مننژیوم
98	96	99	بدون تومور
96	98	94	هیپوفیز

جدول (۳): عملکرد الگوریتم GoogLeNet

F1 Score	Specificity %	Precision %	کلاس
91	85	97	گلیوما
84	97	74	مننژیوم
97	96	99	بدون تومور
92	86	99	هیپوفیز




### ۳-۳-۴- طبقه‌بندی مجموعه داده به کمک VGG19


نمودارهای عملکردی الگوریتم VGG19، دقت در فاز آموزش را تقریباً ۹۹ درصد و در دقت در فاز اعتبارسنجی را ۹۳ درصد بیان می‌نماید، خطا نیز در فاز آموزش تقریباً ۰/۰۱ درصد و در فاز اعتبارسنجی ۰/۱۸ درصد است. جدول شاخص‌های عملکردی الگوریتم VGG19 برای هر چهار کلاس طبقه‌بندی که به ترتیب گلیوما، مننژیوم، تصاویر بدون تومور و هیپوفیز است، بیانگر دقت بالای الگوریتم در تشخیص کلاس تصاویر بدون تومور و تومورهای هیپوفیز و دقت پایین‌تر الگوریتم در تشخیص تصاویر تومورهای مننژیوم است. دقت کلی الگوریتم در طبقه‌بندی تصاویر تومورهای مغزی نیز ۹۴ درصد است.

### ۳-۳-۵- طبقه‌بندی مجموعه داده به کمک ResNet50

نمودارهای عملکردی الگوریتم VGG19، دقت در فاز آموزش را تقریباً ۹۹ درصد و در دقت در فاز اعتبارسنجی را ۹۳ درصد بیان می‌نماید، خطا نیز در فاز آموزش تقریباً ۰/۰۱ درصد و در فاز اعتبارسنجی ۰/۱۸ درصد است. جدول شاخص‌های عملکردی الگوریتم ResNet50 برای هر چهار کلاس طبقه‌بندی که به ترتیب گلیوما، مننژیوم، تصاویر بدون تومور و هیپوفیز است، بیانگر دقت بالای الگوریتم در تشخیص تصاویر بدون تومور و دقت پایین‌تر الگوریتم در تشخیص تصاویر تومورهای مننژیوم است. دقت کلی الگوریتم در طبقه‌بندی تصاویر تومورهای مغزی نیز ۸۵ درصد است.




شکل (۲۸): نمودارهای عملکردی الگوریتم ResNet50




شکل (۲۹): ماتریس در هم‌ریختگی الگوریتم ResNet50

جدول (۶): عملکرد الگوریتم ResNet50


F1 Score	Specificity %	Precision %	کلاس
77	68	89	گلیوما
74	70	78	مننژیوم
96	98	93	بدون تومور
88	99	79	هیپوفیز




شکل (۲۴): نمودارهای عملکردی الگوریتم VGG16



شکل (۲۵): ماتریس در هم‌ریختگی الگوریتم VGG16



شکل (۲۶): نمودارهای عملکردی الگوریتم VGG19



شکل (۲۷): ماتریس در هم‌ریختگی الگوریتم VGG19

جدول (۴): عملکرد الگوریتم VGG16

F1 Score	Specificity %	Precision %	کلاس
95	93	98	گلیوما
92	94	90	مننژیوم
98	98	98	بدون تومور
98	98	98	هیپوفیز

جدول (۵): عملکرد الگوریتم VGG19

F1 Score	Specificity %	Precision %	کلاس
92	85	1	گلیوما
89	96	84	مننژیوم
98	98	98	بدون تومور
98	97	98	هیپوفیز





#### ۴- نتیجه‌گیری

بخش‌بندی تصاویر پزشکی و به‌ویژه تقسیم‌بندی تصاویر مغز باید بسیار دقیق و دقیق‌تر از سایر الگوریتم‌های تقسیم‌بندی تصاویر غیرپزشکی باشد. با تجزیه و تحلیل داده‌های پزشکی به کمک الگوریتم‌های یادگیری عمیق می‌توان نتیجه‌گیری نمود، اگرچه این الگوریتم‌ها چالش‌های زیادی در ارتباط با معرفی یادگیری عمیق در محیط‌های بالینی دارند، اما جزء اولین گزینه‌های انتخابی بوده و روش‌های مختلف یادگیری عمیق به دلیل قدرت بیان فوق‌العاده آن‌ها، نتایج ارزشمندی را تولید می‌کنند. یادگیری عمیق در بررسی تصاویر پزشکی تحت تأثیر پیشرفت‌های بنیادی رایانه‌ای قرار گرفته است. مسابقه‌های بررسی تصاویر پزشکی از جمله مسابقه MICCA و دیگر مسابقات، محققان بیشتری را از جامعه بنیادی رایانه به حوزه بررسی تصاویر پزشکی ترغیب نموده است. بهبودهای بیشتر در شبکه‌های عمیق، زمان آموزش این الگوریتم‌های سه بعدی را کاهش می‌دهد.

در مقاله حاضر تشخیص و طبقه‌بندی تصاویر MRI مورد بررسی قرار گرفت و مشخص شد در مرحله تشخیص الگوریتم‌های VGG16 و ResNet50 با دقت ۹۹/۳۳ بیشترین دقت را داشتند و کمترین دقت در این مرحله به الگوریتم GoogLeNet با دقت ۸۸/۳۳ مربوط می‌شد. در مرحله طبقه‌بندی الگوریتم VGG16 بالاترین دقت را در بین الگوریتم‌ها با مقدار ۹۶ درصد داشت و کمترین دقت مربوط به الگوریتم ResNet50 با دقت ۸۵ درصد بود. لازم به ذکر است این نتایج مربوط به مجموعه داده‌های مشخص شده بوده و ممکن است با تغییر مجموعه داده تغییر نماید. اما مسلم است که الگوریتم VGG16 نسبت به سایر الگوریتم‌ها در هر دو مجموعه داده عملکرد بهتری را ارائه نموده است. همانگونه که در بخش ۳-۲-۶ نیز بیان گردید، تفاوت عملکردی و به ویژه عملکرد بهینه الگوریتم VGG16 را باید به واسطه معماری منحصر به فرد آن و وجود ۱۶ لایه کانولوشنی این الگوریتم دانست. هر چند وجود ۱۲۸ میلیون پارامتر شبکه باعث روند کند در آموزش و تشخیص ویژگی‌ها توسط این الگوریتم می‌شود. باید در نظر داشت دقت بالای این الگوریتم دیگر کمبودها را پوشش می‌دهد. در ضمن می‌توان بیان نمود بهینه‌ترین الگوریتم که با دقت بالا سرعت بیشتری نسبت به VGG16 ارائه می‌دهد، الگوریتم ResNet50 است. این الگوریتم به واسطه وجود ۱۵۲ لایه و استفاده از تکنیک اتصالات پرش دقت بالا و سرعت بهینه را به صورت همزمان ارائه می‌دهد.

#### مراجع

- [1] A. E. Minarno, M. H. C. Mandiri, Y. Munarko, and H. Hariyady, "Convolutional Neural Network with Hyperparameter Tuning for Brain Tumor Classification," *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, vol.6, no.2, pp.127-132, May 2021, doi: 10.22219/KINETIK.V6I2.1219.
- [2] D. H. Gutmann and H. Kettenmann, "Microglia/Brain Macrophages as Central Drivers of Brain Tumor Pathobiology," *Neuron*, vol. 104, no. 3, pp. 442-449, Nov. 2019, doi: 10.1016/J.NEURON.2019.08.028.
- [3] T. Nejo, A. Mende, and H. Okada, "The current state of immunotherapy for primary and secondary brain tumors: similarities and differences," *Japanese Journal of Clinical Oncology*, vol. 50, no.11, pp. 1231-1245, Oct. 2020, doi: 10.1093/JJCO/HYAA164.
- [4] W. Tomaszewski, L. Sanchez-Perez, T. F. Gajewski, and J. H. Sampson, "Brain tumor microenvironment and host state: Implications for immunotherapy," *Clinical Cancer Research*, vol. 25, no. 14, pp. 4202-4210, Jul. 2019, doi: 10.1158/1078-0432.CCR-18-1627.
- [5] C. K. Kuhl, "Abbreviated Magnetic Resonance Imaging (MRI) for Breast Cancer Screening: Rationale, Concept, and Transfer to Clinical Practice," *Annu Rev Med*, vol. 70, pp. 501-519, Jan. 2019, doi: 10.1146/ANNUREV-MED-121417-100403.
- [6] H. H. Sultan, N. M. Salem, and W. Al-Atabany, "Multi-Classification of Brain Tumor Images Using Deep Neural Network," *IEEE Access*, vol. 7, pp. 69215-69225, 2019, doi: 10.1109/ACCESS.2019.2919122.
- [7] A. Gumaei, M. M. Hassan, M. R. Hassan, A. Alelaiwi, and G. Fortino, "A Hybrid Feature Extraction Method with Regularized Extreme Learning Machine for Brain Tumor Classification," *IEEE Access*, vol. 7, pp. 36266-36273, 2019, doi: 10.1109/ACCESS.2019.2904145.
- [8] S. Deepak and P. M. Ameer, "Brain tumor classification using deep CNN features via transfer learning," *Computers in Biology and Medicine*, vol. 111, p. 103345, Aug. 2019, doi:10.1016/J.COMPBIOMED.2019.103345.
- [9] "Brain\_tumor\_Dataset" [https://figshare.com/articles/dataset/brain\\_tumor\\_dataset/1512427](https://figshare.com/articles/dataset/brain_tumor_dataset/1512427) (accessed Jun. 09, 2022).
- [10] Z. N. K. Swati et al., "Brain tumor classification for MR images using transfer learning and fine-tuning," *Comput Med Imaging Graph*, vol. 75, pp.34-46, Jul. 2019, doi:10.11016/J.COMPMEDIMAG.2019.05.001
- [11] N. Noreen, S. Palaniappan, A. Qayyum, I. Ahmad, M. Imran, and M. Shoaib, "A Deep Learning Model Based on Concatenation Approach for the Diagnosis of Brain Tumor," *IEEE Access*, vol. 8, pp. 55135-55144, 2020, doi: 10.1109/ACCESS.2020.2978629.
- [12] H. Hairani, K. E. Saputro, and S. Fadli, "K-means-SMOTE untuk menangani ketidakseimbangan kelas dalam klasifikasi penyakit diabetes dengan C4.5, SVM, dan naive Bayes," *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 2, pp. 89-93, Apr. 2020, doi:10.14710/JTSSISKOM.8.2.2020.89-93.
- [13] S. H. Wang and Y. D. Zhang, "DenseNet-201-Based Deep Neural Network with Composite Learning Factor and Precomputation for Multiple Sclerosis Classification," *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, vol. 16, no. 2s, Jun. 2020, doi: 10.1145/3341095.
- [14] S. Deepak and P. M. Ameer, "Brain tumor classification using deep CNN features via transfer learning," *Computers in Biology and Medicine*, vol. 111, p. 103345, Aug. 2019, doi: 10.1016/J.COMPBIOMED.2019.103345.
- [15] N. Noreen, S. Palaniappan, A. Qayyum, I. Ahmad, M. Imran, and M. Shoaib, "A Deep Learning Model Based on Concatenation Approach for the Diagnosis of Brain Tumor," *IEEE Access*, vol. 8, pp. 55135-55144, 2020, doi: 10.1109/ACCESS.2020.2978629.



- [16] M. C. Xena and Z. Wang, "Brain Tumour Detection and Classification using Multi-Level Ensemble Transfer Learning in MRI Dataset," *icABCD 2021 - 4th International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems, Proceedings*, Aug. 2021, doi: 10.1109/ICABCD51485.2021.9519361.
- [17] N. M. Dipu, S. A. Shohan, and K. M. A. Salam, "Deep Learning Based Brain Tumor Detection and Classification," *2021 International Conference on Intelligent Technologies, CONIT 2021*, Jun. 2021, doi:10.1109/CONIT51480.2021.9498384.
- [18] R. M. Prakash and R. S. S. Kumari, "Classification of MR brain images for detection of tumor with transfer learning from pre-trained CNN models," *2019 International Conference on Wireless Communications, Signal Processing and Networking, WiSPNET 2019*, pp.508–511, Mar. 2019, doi: 10.1109/WISPNET45539.2019.9032811.
- [19] Y. Guo, S. Liu, Z. Li, X. Shang, "BCDForest: a boosting cascade deep forest model towards the classification of cancer subtypes based on gene expression data." *BMC Bioinform* 19(5),118 (2018)
- [20] S. Athisayamani, R.S. Antonyswamy, V. Sarveshwaran, M. Almeshari, Y. Alzamil, V. Ravi, "Feature Extraction Using a Residual Deep Convolutional Neural Network (ResNet-152) and Optimized Feature Dimension Reduction for MRI Brain Tumor Classification. " *Diagnostics* 2023, 13, 668. <https://doi.org/10.3390/diagnostics13040668>
- [21] S.Z. Kurdi, M.H. Ali, M.M. Jaber, T. Saba, A. Rehman, R. Damaševičius. " Brain Tumor Classification Using Meta-Heuristic Optimized Convolutional Neural Networks. " *J. Pers. Med.* 2023, 13, 181. <https://doi.org/10.3390/jpm13020181>
- [22] M.A. Haq, I. Khan, A. Ahmed, S.M. Eldin, A. Alshehri, N.A. Ghamry. " DCNNBT: A novel deep convolution neural network based on brain tumor classification model. " *Fractals* 2023.
- [24] B.S., Abd El-WahabNasr, S. Khamis, et al. " BTC-fCNN: Fast Convolution Neural Network for Multi-class Brain Tumor Classification." *Health Inf Sci Syst* 11, 3 (2023). <https://doi.org/10.1007/s13755-022-00203-w>





Islamic Azad University, Shiraz Branch

نشریه تحلیل مدارها، داده ها و سامانه ها  
Journal of Circuits, Data and Systems Analysis



Cdsa.shiraz.iau.ir

## ناحیه بندی تصاویر مغز نوزادان بر اساس شبکه های عصبی پیچشی

ایران سرافراز<sup>۱</sup>، حامد آگاهی<sup>۲\*</sup>، آذر محمودزاده<sup>۳</sup>

۱- دانشجوی دکتری، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

ideh.sarafraz@gmail.com

۲- دانشیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

hamed.agahi@iau.ac.ir

۳- استادیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

azar.mahmoodzadeh@iau.ac.ir

**چکیده:** در این مقاله، روشی مبتنی بر شبکه های عصبی پیچشی برای ناحیه بندی تصاویر مغز نوزادان ارائه می شود. یکی از چالش های مهم در این زمینه، همپوشانی توزیع شدت روشنایی بافت های ماده خاکستری و ماده سفید است، که منجر به کاهش دقت ناحیه بندی این نواحی می شود. برای افزایش تمایز سطوح خاکستری بین بافت های مغز، در این مقاله یک روش پیش پردازش مبتنی بر شبکه های عصبی پیچشی ارائه می شود که به طور موثری باعث افزایش دقت ناحیه بندی می گردد. برای به دست آوردن ناحیه بندی نهایی، یک شبکه پیچشی دیگر ارائه می شود که بر اساس تصاویر مدالیته T1-T2 ناحیه بندی را انجام می دهد. برای ارزیابی روش پیشنهادی، از دو پایگاه داده iseg2017 و iseg2019 که شامل تصاویر رزونانس مغناطیسی مغز نوزادان است استفاده می شود. نتایج به دست آمده نشان دهنده کارایی مناسب روش پیشنهادی در ناحیه بندی بافت های مغز است. **واژه های کلیدی:** ناحیه بندی، تصاویر رزونانس مغناطیسی، مغز نوزادان، شبکه های عصبی پیچشی، یادگیری عمیق.

## Infant Brain Image Segmentation using the Convolutional Neural Networks

Iran Sarafraz<sup>1</sup>, Hamed Agahi<sup>2\*</sup>, Azar Mahmoodzadeh<sup>3</sup>

<sup>1</sup> PhD Student, Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

ideh.sarafraz@gmail.com

<sup>2</sup> Associate Professor, Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

hamed.agahi@iau.ac.ir

<sup>3</sup> Assistant Professor, Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

azar.mahmoodzadeh@iau.ac.ir

### Abstract:

In this paper, a method based on convolutional neural networks for segmenting neonatal brain images is presented. One of the major challenges in this field is the intensity distribution overlapping between gray matter and white matter tissues, which reduces the segmentation accuracy of these areas. To increase the intensity differentiation between brain tissues, this paper presents a pre-processing method based on convolutional neural networks that effectively increases the segmentation accuracy. To obtain the final segmentation result, another convolutional neural network is proposed which performs segmentation based on T1-T2 images. To evaluate the performance of the proposed method, two databases iseg2017, iseg2019 are used, which include magnetic resonance imaging of infants' brains. The results show the appropriate efficiency of the proposed method in segmenting brain tissues.

**Keywords:** Segmentation, magnetic resonance images, Infants' brain, Convolutional neural networks, Deep learning.

DOI: 00.00000/0000

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۲/۰۳/۲۰

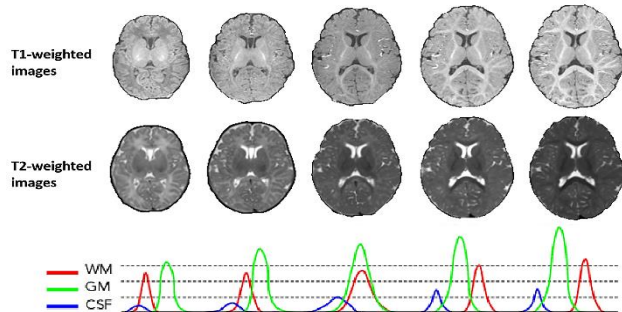
تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۲۴

تاریخ ارسال مقاله: ۱۴۰۲/۰۱/۱۱

## ۱ - مقدمه

کنتراست نسبی خوبی بین بافت‌های مغز در سنین شیرخوارگی و اوایل بزرگسالی وجود دارد. اما، در سنین پایین، توزیع شدت روشنایی در بافت‌های ماده خاکستری و ماده سفید (به ویژه در نواحی قشر مغز) تا حد زیادی با هم همپوشانی دارند. همین مسئله منجر به کاهش تمایز سطوح خاکستری بین بافت‌های مغز می‌شود. همچنین رشد مغز در نواحی مختلف، غیرخطی بوده و کنتراست در نواحی مختلف مغز متفاوت است [۶]. عوامل و مشکلات دیگری نیز در تصاویر مغز نوزادان وجود دارد. از جمله آن‌ها می‌توان به موارد زیر اشاره کرد: آثار حرکت مغز در حین تصویربرداری، اندازه حجمی کم تصاویر به دلیل کوچک بودن اندازه مغز نوزاد، وضوح محدود، نسبت سیگنال به نویز و نسبت کنتراست به نویز پایین و همچنین میلین‌سازی ناقص و سطح بالای آن در مغز نوزادان. تمامی موارد بیان شده، ناحیه‌بندی خودکار تصاویر مغز نوزادان را به یک کار بسیار چالش برانگیز تبدیل می‌کند. از این رو، ابزارهای محاسباتی که برای پردازش تصاویر مغز بزرگسالان استفاده می‌شوند (مانند SPM، FSL، BrainSuite، CIVET، FreeSurfer و HCP Pipeline) اغلب عملکرد ضعیفی را بر روی تصاویر MRI مغز نوزادان دارند [۷].

در سال‌های اخیر، روش‌ها و رویکردهای مختلفی برای ناحیه‌بندی نواحی مغز در تصاویر MRI ارائه شده است. یک رویکرد رایج برای ناحیه‌بندی خودکار، استفاده از اطلس‌ها برای مدل‌سازی آناتومیکی مغز و بهره گرفتن از آن برای ناحیه‌بندی است [۸، ۹، ۱۰]. در چنین رویکردی، یک اطلس (یا اطلس‌های متعدد) ابتدا در یک تصویر هدف ثبت می‌شود و سپس با تعمیم برچسب‌های دستی به این تصویر ثبت شده، ناحیه‌بندی تصویر هدف به دست می‌آیند. هنگامی که چندین اطلس در نظر گرفته می‌شود، برچسب‌ها از اطلس‌های مختلف را می‌توان از طریق یک استراتژی ترکیب برچسب [۱۱، ۱۲، ۱۳] ایجاد کرد و ناحیه‌بندی نهایی را به دست آورد. روش‌های مبتنی بر اطلس به‌طور گسترده در کاربردهای تقسیم‌بندی استفاده شده‌اند. اگرچه این روش‌ها در بسیاری از کاربردها عملکرد خوبی را ارائه کرده‌اند، اما معمولاً به فرآیند ثبت، بسیار حساس هستند و اگر تصویر، کنتراست پایینی داشته باشد یا تصویر ساختار مغز دارای تنوع زیادی باشد،



شکل (۱): تصاویر MR با وزن T1 (سطر اول) و T2 (سطر دوم) از یک نوزاد در سنین تازه دو هفته‌گی تا دوازده ماهگی به همراه توزیع نواحی مختلف مغزی در سنین مختلف (سطر سوم)

سال اول زندگی، پویاترین مرحله رشد مغز انسان پس از تولد بوده که با رشد سریع بافت و توسعه طیف وسیعی از عملکردهای شناختی و حرکتی همراه است [۱]. افزایش دسترسی به تصاویر رزونانس مغناطیسی چند وجهی مانند تصاویر T1w و T2w فرصت مناسبی را برای مطالعه دقیق و قابل اعتماد مراحل تکاملی مغز در اختیار ما قرار داده است. تصویربرداری T2w باعث می‌شود ساختارهایی با آب زیاد در تصاویر، روشن به نظر برسند و تصویربرداری T1w آب را تاریک و ساختارهای حاوی چربی را نسبتاً روشن نشان می‌دهد. بنابراین، تصویربرداری T1w برای ارزیابی ساختارهایی که دارای چربی بالا هستند (مانند مفاصل) مفید است. در حالی که تصویربرداری T2w برای ارزیابی ساختارهای غنی از آب مانند مایع مغزی و همچنین برای جستجوی التهاب موضعی مفید است. از اینرو، به کمک این تصاویر می‌توان ناهنجاری‌های رشد مغز را تشخیص داد. در سال‌های اخیر با ذخیره دیجیتال این تصاویر و بایگانی آن‌ها، مجموعه داده‌های مختلفی وجود دارد. این مجموعه داده‌ها بدون شک دانش ما را در مورد رشد طبیعی اولیه مغز افزایش می‌دهد و بینش‌های مهمی را در مورد منشاء و مسیرهای رشد غیرطبیعی، اختلالات رشد عصبی (مانند اوتیسم، اسکیزوفرنی، اختلال دوقطبی) و کمبود توجه و بیش‌فعالی ارائه می‌کند. این تصویر برداری در مطالعه مشکلات رشد مغز نوزادان بسیار کاربردی است و به محققان اجازه می‌دهد تا نقایص رشد مغز را ارزیابی، هنجار بودن مغز را اندازه‌گیری، و کودکان در معرض خطر بالای اختلالات رشد عصبی را شناسایی کنند.

یکی از گام‌های اساسی در مطالعه رشد طبیعی و غیرعادی اولیه مغز نوزادان، تقسیم‌بندی دقیق تصاویر MRI مغز نوزاد به مناطق مختلف مورد علاقه است [۲، ۳]. بافت مغز به طور کلی از سه ناحیه شامل ماده سفید، ماده خاکستری و مایع مغزی نخاعی تشکیل شده است. ناحیه‌بندی قسمت‌های مختلف مغز در ساخت اطلس مغز و همچنین بررسی رشد مغز، اهمیت زیادی دارد [۴، ۵]. در شکل (۱) تصاویر MRI مربوط به سنین مختلف از دو هفته‌گی تا یک سالگی نوزاد نشان داده شده است. در سنین کمتر از پنج ماهگی، بافت ماده خاکستری توزیع بیشتری نسبت به سنین بالاتر دارد و بخش زیادی از مغز را به خود اختصاص داده است. همانطور که در شکل مشاهده می‌شود، در بازه زمانی سنین شش تا نه ماهگی، بافت‌های مغز رشد سریع‌تری داشته که باعث افزایش شدت ماده سفید در تصاویر T1w شده و در نتیجه تمایز بیشتری با سایر نواحی ماده خاکستری و ماده سفید ایجاد می‌شود (که برای تصاویر T2w نیز صادق است). الگوی بافت مغز در سنین بیشتر از نه ماهگی شبیه به الگوی بزرگسالان بوده که در آن شدت ماده خاکستری در تصاویر T1w بسیار کمتر از ماده سفید است. توزیع شدت بافت مربوط به سنین مختلف در ردیف سوم شکل (۱) نشان داده شده است. همانطور که مشاهده می‌شود،

یکی از مشکلات عمده در اکثر روش‌های پیشنهادی، وجود عدم قطعیت سطوح خاکستری بین بافت‌های مختلف مغز نوزادان است که این موضوع ناشی از عدم رشد کامل مغز نوزادان است. این در حالی است که بافت مغز افراد بالغ به دلیل رشد کامل، امکان تفکیک مناسب‌تری دارد. این عامل باعث کاهش کارایی روش‌های ارائه شده در ناحیه‌بندی مغز نوزادان می‌شود. همگن نبودن سطوح خاکستری بافت‌های مختلف موجود در مغز نوزادان، یکی دیگر از چالش‌های مهم در شناسایی آن‌ها است. در این مقاله، یک روش مبتنی بر شبکه‌های عصبی پیچشی برای افزایش تمایز سطوح خاکستری بین بافت‌های مغز ارائه شده که از طریق انجام یک پیش‌پردازش مبتنی بر پیکسل به طور موثری باعث افزایش دقت ناحیه‌بندی می‌شود. روش پیش‌پردازش ارائه شده همچنین با افزایش یکنواختی و همگنی بافت‌های مختلف، منجر به بهبود دقت ناحیه‌بندی می‌شود. همچنین یک شبکه پیچشی دیگر برای ناحیه‌بندی مبتنی بر تصاویر T1 و T2 ارائه شده است.

ساختار ادامه مقاله به صورت زیر است: در بخش ۲، مراحل روش پیشنهادی به طور کامل توضیح داده خواهد شد. در بخش ۳، نتایج به دست آمده از شبیه‌سازی روش پیشنهادی ارائه می‌شود و در نهایت در بخش ۴، مقاله با یک نتیجه‌گیری به پایان می‌رسد.

## ۲- روش پیشنهادی

یکی از مهمترین چالش‌ها در طبقه‌بندی تصاویر مغز نوزادان، مشخص نبودن مرز بافت‌های مختلف موجود در مغز در مقایسه با مغز افراد بزرگسال است. در روش پیشنهادی، قبل از انجام ناحیه‌بندی، یک عملیات پیش‌پردازش بر روی تصویر ورودی MRI انجام می‌شود تا بتوان سطوح خاکستری بافت‌های مغزی را هر چه بیشتر از هم تفکیک کرد و متعاقباً ناحیه‌بندی دقیق‌تری انجام داد. بلوک دیاگرام روش پیشنهادی در شکل ۲ نشان داده شده است. همانطور که مشاهده می‌شود، روش پیشنهادی از دو بخش عمده پیش‌پردازش و ناحیه‌بندی تشکیل شده است. در ادامه این دو بخش توضیح داده می‌شود.

### ۲-۱- پیش‌پردازش عمیق

در اولین گام از روش پیشنهادی، یک روشی مبتنی بر شبکه‌های عصبی کانولوشنی برای تفکیک بیشتر بین بافت‌های مغز ارائه شده است. مدل پیشنهادی، یک شبکه U-Net بر اساس یک مدل رگرسیون است که ورودی آن تصویر MRI و خروجی، تصویر پیش‌پردازش شده است. این مدل U-Net شامل چندین لایه مشتمل بر لایه‌های کانولوشن، ماکس-پولینگ، آپ-کانولوشن و ترکیب است. به صورت کلی، مدل U-net دارای دو بخش رمزگذار و رمزگشا است. در بخش رمزگذار، تصویر توسط لایه‌هایی مانند کانولوشن و ماکس-پولینگ به یک فضای فشرده ویژگی منتقل می‌شود و در بخش رمزگشا، تصویر پیش‌پردازش به عنوان خروجی تولید می‌شود.

ممکن است با شکست مواجه شوند. این امر به ویژه در مورد تقسیم‌بندی مغز نوزاد، به دلیل تفاوت‌های زیاد و تنوع فضایی بالای مغز نوزادان مشکل ساز است. برای غلبه بر محدودیت‌های روش‌های مبتنی بر اطلس، از مدل‌های پارامتریک مانند مدل‌های تغییر شکل‌پذیر [۱۶، ۱۵، ۱۴] استفاده شده است. مدل‌های پارامتریک معمولاً تقسیم‌بندی را به‌عنوان یک مسئله بهینه‌سازی یک تابع انرژی بیان می‌کنند. چنین مدل‌هایی اغلب به تعداد زیادی تصاویر برچسب‌دار نیاز دارند، که در عمل به ندرت در دسترس هستند. مدل‌های تغییر شکل‌پذیر، نتایج به دست آمده توسط اطلس را به شیوه‌ای تکراری اصلاح می‌کنند تا بهتر با مرزهای نواحی مغز هماهنگ شوند. با این حال، این مدل‌ها معمولاً به ساختار مغز وابسته هستند.

اخیراً، روش‌های یادگیری عمیق مبتنی بر شبکه‌های عصبی پیچشی عملکرد فوق‌العاده‌ای را در طیف گسترده‌ای از کاربردهای بینایی ماشین و تحلیل تصویر نشان داده‌اند. به طور خاص، CNN‌ها برای مشکلات مختلف، از جمله تقسیم‌بندی MRI مغز نوزادان به نتایج پیشرفته‌ای دست یافته‌اند [۱۷-۲۲]. به عنوان نمونه، در [۱۷] یک ساختار دو بعدی CNN چند مقیاسی ارائه شده که با استفاده از مدالیته تصویر T2w تقسیم‌بندی دقیق و سازگاری انجام می‌دهد. برای به دست آوردن اطلاعات چند مقیاسی، نویسندگان فیلترهایی با اندازه‌های مختلف را در نظر گرفتند. در چندین مطالعه اخیر به منظور غلبه بر کنتراست بسیار کم بین بافت‌های ماده سفید و ماده خاکستری و افزایش دقت ناحیه‌بندی، از تصاویر با مدالیته‌های مختلف به عنوان ورودی استفاده شده است. به عنوان نمونه، در [۱۸] یک CNN عمیق با ترکیب تصاویر T1 و T2 و ناهمسانگردی کسری پیشنهاد شد. در تحقیقی دیگر، یک شبکه عصبی کاملاً پیچشی (FCNN) برای تقسیم‌بندی تصاویر MR مغز نوزادان پیشنهاد شده است [۱۹]. همچنین در [۲۰] یک روش جدید مبتنی بر شبکه سه بعدی U-Net مطرح گردیده است. در ساختار پیشنهادی آن‌ها، با این هدف که در مرحله رمزگذاری، اطلاعات معنایی کمی از دست برود از کانولوشن گسترش یافته استفاده شده است. در [۲۱]، از تطبیق هیستوگرام برای کم کردن تفاوت سطوح روشنایی پیکسل‌های تصاویر و یکسان‌سازی سطوح خاکستری استفاده شده است. در این روش همچنین یک شبکه سه بعدی U-Net ارائه شده که به ازای ورودی‌های با مدالیته‌های T1 و T2، ناحیه‌بندی انجام می‌شود. در [۲۲]، از ترکیب شبکه‌های عصبی عمیق VGG-16 و U-Net برای ناحیه‌بندی مغز استفاده شده است. در مطالعات انجام شده همچنین از اطلاعات فازی در شبکه‌های عمیق به منظور بخش‌بندی مغز نوزادان استفاده شده است [۲۳]. در [۲۴] ابتدا به پیش‌پردازش تصاویر پرداخته شده و سپس از شبکه عصبی کاملاً پیچشی (FCN) جهت تقسیم‌بندی نواحی مختلف مغز استفاده شده است. همچنین در [۲۵] تقسیم‌بندی با توجه به ویژگی‌های بافتی مغز انجام پذیرفته است و سپس از تصاویر چندوجهی به عنوان ورودی برای شبکه U-Net با چند مسیر، پیشنهاد شده است.



از آنجایی که در یک تصویر MRI، امکان دارد برخی از برش‌ها به نواحی خارج از مغز مربوط باشد، لذا در این بخش نیاز هست برش‌های دیگر که شامل اطلاعات مغزی نیست حذف شود تا آموزش مدل U-net بهتر انجام شود. برای انجام این کار از روش آستانه‌گذاری Otsu استفاده می‌شود که یک روش برای آستانه‌گذاری بهینه است و هدف آن، یافتن مقدار آستانه بهینه است به طوری که مجموع واریانس‌های پیش‌زمینه و پس‌زمینه حداقل باشد. در این روش همه پیکسل‌های تصویر با یک سطح آستانه مقایسه می‌شود و اگر مقدار سطح خاکستری پیکسل مورد نظر از آستانه بیشتر باشد آن پیکسل متعلق به یک بافت مغزی در نظر گرفته می‌شود و در غیر این صورت، به عنوان پیکسل پس‌زمینه لحاظ می‌شود.

$$Brain_{mask}(X_i) = \begin{cases} 1 & \text{if } im(X_i) \geq t^* \\ 0 & \text{if } im(X_i) < t^* \end{cases} \quad (1)$$


در این رابطه،  $Brain_{mask}$  یک ماسک باینری حاصل از آستانه‌گذاری است که شامل ناحیه تقریبی بافت مغز است و  $t^*$  آستانه بهینه Otsu است. بعد از اعمال این آستانه‌گذاری ناحیه بافت مغز به دست می‌آید. در شکل (۳) برای چند تصویر نمونه نتیجه حاصل نشان داده شده است. بعد از شناسایی نواحی مغزی در هر برش، آن دسته از تصاویر برش که شامل هیچ ناحیه مغز نیست حذف می‌شود و در مراحل بعدی فقط از برش‌های حاوی ناحیه مغز برای آموزش مدل U-net استفاده می‌گردد. برای آموزش هر یک از مدل‌های U-net، از تمامی برش‌های تصویر MRI که در بخش قبل استخراج شدند به عنوان ورودی استفاده می‌شود. اما برای آموزش این مدل‌ها، علاوه بر داشتن تصاویر ورودی، تصاویر خروجی هدف (تصاویر پیش پردازش شده) نیز باید از روی داده‌های آموزش تولید شوند. لذا در این مرحله برای تمامی برش‌های به دست آمده از داده آموزش، باید تصاویر خروجی دلخواه تولید شود. همانطور که قبلاً ذکر شد، هدف کلی روش پیش‌پردازش عمیق پیشنهادی، افزایش اختلاف سطوح خاکستری بافت‌های مغز است. لذا برای تولید تصاویر خروجی، باید اختلاف سطوح خاکستری بافت‌های مغز افزایش یابد. برای انجام این کار طبق شکل (۴)، به صورت زیر عمل می‌شود:

۱- بر اساس برچسب‌هایی که برای بافت‌های مختلف مغزی در داده آموزش در اختیار است، سه بافت سفید، خاکستری و مایع مغزی از هم تفکیک می‌شود.

۲- مقدار سطح خاکستری هر پیکسل در هر بافت، معادل  $k$  برابر میانگین آن کلاس قرار داده می‌شود. به عنوان مثال، پیکسل‌هایی که به کلاس بافت سفید متعلق هستند، شناسایی می‌شود. سپس میانگین سطوح خاکستری تمامی آن پیکسل‌ها به دست می‌آید. اگر مقدار میانگین سطوح خاکستری بافت سفید تصویر،  $M$  در نظر گرفته شود، مقدار سطح خاکستری همه پیکسل‌های بافت سفید آن تصویر برابر  $P_{ij} \times M \times k$  قرار داده می‌شود. این کار برای دو ناحیه بافت خاکستری و مایع مغزی نیز انجام می‌شود تا تصویر پیش-پردازش شده تولید شود. مقدار عدد  $k$  برای کلاس‌های پس‌زمینه،


بخش رمزگذار مدل U-net شامل سه مجموعه لایه کانولوشن است: مجموعه اول شامل دو لایه کانولوشن متوالی با تعداد ۳۲ فیلتر، مجموعه دوم شامل دو لایه کانولوشن متوالی با تعداد ۶۴ فیلتر و مجموعه سوم شامل دو لایه کانولوشن متوالی با تعداد ۱۲۸ فیلتر است. هرچه تعداد مجموعه لایه‌های کانولوشن شبکه U-net بیشتر شود عمق بخش رمزگذار بیشتر می‌شود و مدل می‌تواند ویژگی‌های فشرده‌تری را استخراج کند. بخش رمزگشای مدل ارائه شده نیز شامل دو مجموعه لایه کانولوشن است که هدف آن‌ها بازسازی تصویر خروجی از ویژگی‌های فشرده است. در این مدل، مجموعه لایه کانولوشن اول شامل دو لایه متوالی با تعداد ۶۴ فیلتر بوده در حالی که مجموعه لایه کانولوشن دوم شامل دو لایه متوالی با تعداد ۱۲۸ فیلتر است. در بخش رمزگشا، همچنین یک لایه آپ-کانولوشن وجود دارد که وظیفه آن افزایش دو برابری رزولوشن مکانی نقشه و ویژگی است. به عنوان مثال، اگر در خروجی لایه کانولوشن، نقشه ویژگی با ابعاد  $10 \times 10$  و با عمق ۶۴ وجود داشته باشد (با اعمال لایه آپ-کانولوشن نقشه ویژگی با ابعاد  $20 \times 20$  و با عمق ۶۴  $20 \times 20 \times 64$ ) به دست می‌آید.

مدل U-net همچنین شامل یک لایه dropout است که برای آموزش بهتر مدل و جلوگیری از بیش‌برازش<sup>۱</sup> استفاده شده است. وقتی یک مدل بیش از حد آموزش می‌بیند به این معنی است که بر روی داده‌های آموزش خوب عمل می‌کند در حالی که نتیجه مناسبی بر روی داده آزمایش به دست نمی‌آید. در واقع این لایه کمک می‌کند که مدل بتواند به خوبی ساختارهای مختلف تصویر را آموزش ببیند و صرفاً یک ناحیه یا نواحی از پیکسل‌های تصویر را یاد نگیرد. به دلیل اینکه تصاویر MRI شامل دو مدالیته T1 و T2 هستند، در این مقاله دو مدل U-net مجزا برای پیش پردازش این تصاویر ارائه شده است. برای آموزش هر یک از مدل‌های مذکور، در اولین گام، تمامی برش‌های تصویر MRI استخراج می‌شود و به صورت یک تصویر دو بعدی ذخیره می‌گردد. در واقع، به جای تحلیل تصویر سه بعدی MRI، آن تصاویر به تصاویر دو بعدی تجزیه می‌شود. این کار از بار پردازشی مدل U-net کاسته و این امکان را فراهم می‌کند که بتوان مدل مورد نظر را به سرعت آموزش داد.




شکل (۲): بلوک دیاگرام روش پیشنهادی برای ناحیه بندی تصاویر مغز نوزادان

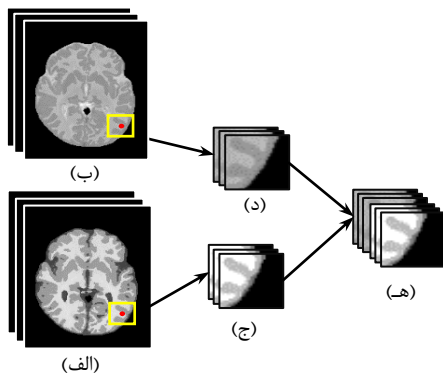
<sup>1</sup> Overfitting



شکل (۳): آستانه‌گذاری برای شناسایی ناحیه مغز در هر برش



شکل (۴): نحوه تولید تصویر پیش‌پردازش شده از یک تصویر برش نمونه برای آموزش مدل‌های U-net



شکل (۵): نحوه استخراج یک بلوک از تصویر MRI: (الف) تصویر T1، (ب) تصویر T2، (ج) بلوک استخراجی از تصویر T1 به اندازه  $21 \times 21 \times 21$  به مرکزیت پیکسل (i,j)، (د) بلوک استخراجی از تصویر T2 به اندازه  $21 \times 21 \times 21$  به مرکزیت پیکسل (i,j)، (ه) بلوک با ابعاد  $21 \times 21 \times 42$  پیکسل حاصل از ترکیب بلوک‌های T1 و T2

مایع مغزی نخاعی، بافت ماده خاکستری و ماده سفید به صورت تجربی به ترتیب برابر ۱، ۲، ۳ و ۴ در نظر گرفته می‌شود.  $P_{i,j}$  نیز سطح خاکستری پیکسل ستون  $i$  و سطر  $j$  از تصویر است. با تولید نواحی پیش‌پردازش شده بافت خاکستری، بافت سفید و مایع مغزی، این سه ناحیه با عملگر جمع با هم ترکیب می‌شوند تا تصویر پیش‌پردازش شده کل ناحیه مغز به دست آید. متعاقب دو مرحله ذکر شده، نسخه پیش‌پردازش شده برای هر یک از برش‌های داده آموزش به دست می‌آید که می‌توان آن‌ها را برای آموزش مدل‌های U-net استفاده نمود.

## ۲-۲- ناحیه بندی

در بخش قبل، تصاویر پیش‌پردازش شده توسط مدل‌های U-net به دست آمد. در این بخش، بر اساس این تصاویر، ناحیه‌بندی برش‌ها توسط مدل کانولوشنی عمیق پیشنهادی انجام می‌گیرد. برای انجام ناحیه‌بندی، از طبقه‌بندی مبتنی بر بلوک<sup>۱</sup> استفاده می‌شود. برای ناحیه‌بندی، ابتدا تصاویر سه بعدی MRI با ابعاد  $192 \times 144$  پیکسل و تعداد برش‌های ۲۵۶، به بلوک‌های کوچک با ابعاد  $21 \times 21 \times 21$  تقسیم می‌شود. این بدان معنی است که اندازه بلوک در راستای مختصات دو بعدی تصویر برابر  $21 \times 21$  بوده و تعداد ۲۱ برش را شامل می‌شود. باید توجه داشت که بلوک‌های استخراج شده از تصویر، بلوک‌های همپوشان هستند. در واقع در این بخش، اطراف هر پیکسل تصویر، یک بلوک به اندازه  $21 \times 21 \times 21$  پیکسل در نظر گرفته می‌شود. لذا اگر اندازه هر برش تصویر MRI، برابر  $N$  در  $M$  پیکسل باشد، در این صورت از آن تصویر به تعداد  $M \times N$  بلوک استخراج می‌شود. حال اگر تصویر MRI، شامل  $C$  برش باشد در آن صورت به صورت کلی  $M \times N \times C$  بلوک از آن تصویر استخراج می‌شود. از آنجایی که دو مدالیته T1 و T2 برای تصاویر سه بعدی MRI وجود دارد، این کار برای هر دو مدالیته انجام می‌شود و طبق شکل (۵) بلوک‌های متناظر استخراجی از دو مدالیته ذکر شده در راستای عمیق در کنار هم قرار داده می‌شود تا یک بلوک با اندازه  $21 \times 21 \times 42$  پیکسل حاصل شود که شامل اطلاعات مربوط به هر دو مدالیته است. برچسب هر بلوک برابر با یک عدد خواهد بود که نشان‌دهنده کلاس پیکسل به مرکزیت آن بلوک است. هر بلوک می‌تواند به یکی از چهار کلاس بافت سفید (WM)، بافت خاکستری (GM)، مایع مغزی (CSF) و یا پس‌زمینه تعلق داشته باشد. ساختار مدل پیشنهادی پیچشی برای ناحیه‌بندی در جدول (۱) نشان داده شده که شامل چهار لایه کانولوشن، سه لایه ماکس-پولینگ و دو لایه تماماً متصل (FC)<sup>۲</sup> است. مدل پیشنهادی این امکان را می‌دهد که بتوان مسئله ناحیه‌بندی را به یک مسئله طبقه‌بندی تبدیل کرده و تصاویر حاصل از مرحله پیش‌پردازش را طبقه‌بندی کرد. برای آموزش هر چه بهتر مدل و جلوگیری از بیش‌برازش، از تکنیک افزایش داده استفاده می‌شود. این تکنیک در افزایش تنوع داده آموزش برای آموزش مدل‌های عمیق مورد استفاده قرار می‌گیرد.

<sup>2</sup> Fully-Connected (FC)

<sup>1</sup> Patch-based classification



جدول (۱): ساختار شبکه پیچشی روش پیشنهادی

لایه	تعداد فیلتر	اندازه فیلتر	استراید	خروجی
Input	-	-	-	21×21×42
Conv	32	3×3×3	1×1	21×21×32
BN + ReLU	-	-	-	21×21×32
Max-pool	1	2×2	2×2	10×10×32
Conv	64	3×3×3	1×1	10×10×64
BN + ReLU	-	-	-	10×10×64
Max-pool	1	2×2	2×2	5×5×64
Conv	128	3×3×3	1×1	5×5×128
BN + ReLU	-	-	-	5×5×128
Max-pool	1	2×2	2×2	2×2×128
Conv	256	3×3×3	1×1	2×2×256
BN + ReLU	-	-	-	2×2×256
FC	256	-	-	1×1×256
ReLU	-	-	-	1×1×256
FC	3	-	-	1×1×3
Softmax	-	-	-	1×1×3


جدول (۲): پروتکل تصویربرداری تصاویر آموزش

دو پایگاه داده iSeg 2017 و iSeg 2019

مدالیتی	تعداد برش	TR/TE	زاویه تلنگر	وضوح
T1	۱۴۴ (ساجیتال)	۱۹۰۰ / ۴.۳۸ ms	۷ درجه	۱ × ۱ × ۱ میلی مترمربع
T2	۶۴ (آگزیتال)	۷۳۸۰ / ۱۱۹ ms	۱۵۰ درجه	۱.۹۵ × ۱.۲۵ × ۱.۲۵ میلی مترمربع

جدول (۳): پروتکل تصویربرداری تصاویر تست پایگاه داده iSeg 2019

داده	مدالیتی	TR/TE	زاویه تلنگر	وضوح
BCP	T1	۲.۲۴ ms / ۲۴۰۰	۸ درجه	۰.۸ × ۰.۸ × ۰.۸ میلی مترمربع
	T2	۵.۶۴ ms / ۳۲۰۰	۷ درجه	۰.۸ × ۰.۸ × ۰.۸ میلی مترمربع
دانشگاه استنفورد	T1	۲.۹ ms / ۷۶	۱۱ درجه	۰.۸ × ۰.۸ × ۰.۸ میلی مترمربع
	T2	۹۱.۴ ms / ۲۵۰۲	۹۰ درجه	۰.۸ × ۱ × ۱ میلی مترمربع
دانشگاه اموری	T1	۲.۱۹ ms / ۲۴۰۰	۸ درجه	۱ × ۱ × ۱ میلی مترمربع
	T2	۵۶۱ ms / ۳۲۰۰ / ۱۲۰	۱۲۰ درجه	۱ × ۱ × ۱ میلی مترمربع



شکل (۶): اعمال روش‌های مختلف افزایش داده بر روی یک بلوک استخراج شده نمونه: (الف) تصویر نمونه، (ب) یک ناحیه از تصویر نمونه، (ج) تصاویر تولیدی توسط روش‌های مختلف افزایش داده

در روش پیشنهادی در این مقاله از چندین تکنیک افزایش داده از جمله چرخش، مقیاس، یکنواختی، تغییر سطح روشنایی و تغییر کنتراست استفاده شده که به شرح زیر هستند:

- چرخش: به اندازه مضربی از ۹۰ درجه
- مقیاس: به نسبت ۰/۸ تا ۱/۲
- یکنواختی: توسط فیلتر گوسی به ازای سیگما ۱/۲ تا ۳ و اندازه پنجره ۵×۵

در شکل (۶)، نمونه‌هایی از بلوک‌های به دست آمده توسط روش‌های مختلف افزایش داده، نشان داده شده است. بعد از آموزش مدل‌های U-net و مدل کانولوشنال ارائه شده، برای به دست آوردن نتیجه نهایی ناحیه‌بندی برای یک تصویر پیش‌پردازش شده آزمایشی، بدین صورت عمل می‌شود که ابتدا تصویر به بلوک‌های کوچک تقسیم می‌شود. سپس هر بلوک از مدل پیچشی پیشنهادی عبور داده شده تا برچسب آن تخمین زده شود. در نهایت مقدار پیکسل واقع در مرکز بلوک موردنظر، برابر کلاس تخمین زده شده توسط مدل پیچشی قرار داده می‌شود. این کار برای تمامی بلوک‌های تصویر انجام داده می‌شود تا تصویر ناحیه‌بندی شده نهایی به دست آید.

### ۳- ارزیابی نتایج

در این بخش، عملکرد روش پیشنهادی بررسی و نتایج آن با سایر روش‌های موجود مقایسه می‌شود. در این راستا، دو پایگاه داده مورد استفاده معرفی می‌شود. همچنین معیارهای ارزیابی نیز توضیح داده می‌شود.

#### ۳-۱- پایگاه‌های داده

برای ارزیابی عملکرد روش‌های پیشنهادی، از دو پایگاه داده iSeg 2017 [۲۶] و iSeg 2019 [۲۷] استفاده می‌شود. این مجموعه داده‌ها شامل تصاویر مختلف MRI مغز نوزادان با ابعاد ۱۹۲×۱۴۴ پیکسل و تعداد برش‌های ۲۵۶ بوده که در دو پروتکل T1 و T2 تصویربرداری شده‌اند. مجموعه داده iSeg 2017 حاوی تصاویر اسکن‌های MR مختلف از نوزادان است. همه نوزادان مورد مطالعه در این پایگاه داده، سن بین ۵/±۰ ماه داشتند. اسکن‌های MR، توسط اسکن‌های زمینس سه تسلا انجام شده و در طول اسکن، نوزادان در خواب بوده و مجهز به محافظ گوش بودند و سر آن‌ها در دستگاه تثبیت خلاء، محکم شده بود. جزئیات مربوط به پروتکل تصویربرداری این پایگاه داده در جدول (۲) ذکر شده است [۲۶]. در این پایگاه داده، هر تصویر شامل یک تصویر دارای برچسب بوده که نشان‌دهنده نتیجه ناحیه‌بندی توسط یک رادیولوژیست است. تصویر برچسب نیز همانند تصاویر MRI، به صورت حجمی بوده و هم اندازه تصاویر MRI است. در تصویر برچسب، هر پیکسل به یکی از چهار کلاس پس‌زمینه، بافت خاکستری، بافت سفید و مایع مغز تعلق دارد. این پایگاه داده شامل ده تصویر MRI مغزی برای بخش آموزش و سیزده تصویر برای بخش تست و ارزیابی است.



### ۳-۳- پارامترهای آموزش و نتایج ارزیابی

برای آموزش مدل U-net، در این مقاله از برش‌های استخراج شده تمامی تصاویر MRI از داده آموزش استفاده می‌شود. به دلیل اینکه خروجی مدل پیشنهادی، یک تصویر سطح خاکستری پیش‌پردازش شده است، لذا این مدل، یک مدل رگرسیون بوده و برای آموزش آن از تابع هزینه میانگین مربعات خطا<sup>۴</sup> استفاده می‌شود. برای بهینه‌سازی این تابع هزینه در فرآیند آموزش مدل، از روش بهینه‌سازی آدم [۲۸] استفاده شده است. این روش در تکرارهای مختلف در مرحله آموزش، با حداقل‌سازی تابع هزینه، وزن‌های مدل را به روز رسانی می‌کند. سایر پارامترهای مدل U-net پیشنهادی در جدول (۴) نشان داده شده است. برای آموزش مدل، اندازه mini-batch برابر ۱۶ انتخاب شده است. انتخاب mini-batch های بزرگتر به همگرایی سریع‌تر کمک می‌کند اما بار محاسباتی نیز افزایش پیدا می‌کند. تعداد کل تکرار برای آموزش مدل، ۲۰۰ و همچنین نرخ یادگیری اولیه، ۰/۰۱ در نظر گرفته شده که مقدار آن به ازای هر ۳۰ تکرار با ضریب ۰/۸ کاهش پیدا می‌کند تا آموزش مدل بهتر انجام شود.

در مجموعه داده آموزش تنها ده تصویر MRI در اختیار است که از هر تصویر، برش‌هایی که شامل بافت مغز هستند استخراج و برای آموزش مدل U-net استفاده می‌شود. با این حال، تعداد برش‌های موجود برای آموزش مدل همچنان ناکافی است. لذا، قبل از آموزش مدل، از چندین روش افزایش داده به شرح زیر استفاده شده است:

- **جابجایی:** تصویر به اندازه  $\pm 20$  و  $\pm 40$  پیکسل جابجا می‌شود. در نتیجه، از هر تصویر برش چهار نسخه جدید به دست می‌آید. این عملیات، مدل را در برابر جابجایی پیکسل‌های نواحی مغز مقاوم می‌کند.

- **انعکاس:** در این روش، تصویر هر برش به صورت عمودی و افقی انعکاس داده می‌شود. لذا از هر برش دو نسخه جدید ایجاد می‌شود.
- **تغییر شدت روشنایی:** در این روش، شدت روشنایی هر برش تغییر داده می‌شود. برای اینکار از تابع گاما به ازای گام‌های ۰/۲۵، ۰/۵، ۱، ۱/۵ استفاده می‌شود. تابع گاما به ازای مقدار گامی کمتر از ۱، باعث تاریک‌تر شدن تصویر می‌شود، در حالی که به ازای گامی بزرگ‌تر از ۱ باعث روشن‌تر شدن تصویر می‌شود.

جدول ۴: پارامترهای آموزش مدل U-net

پارامتر	مقدار
نرخ یادگیری	۰/۰۱
تعداد تکرار	۲۰۰
mini-batch	۱۶
ضریب کاهش نرخ یادگیری	۰/۸
تابع هزینه	میانگین مربعات خطا

مجموعه داده دیگر مورد استفاده در این مقاله، iSeg 2019 است. این پایگاه داده نیز شامل تصاویر اسکن‌های MR مختلف از نوزادان شش ماهه است که در دو مدالیته T1 و T2 تهیه شده‌اند [۲۷]. این پایگاه داده شامل ده تصویر آموزش، سیزده تصویر ارزیابی و شانزده تصویر تست است که هر دو بخش آموزش و ارزیابی با دستگاه MRI سه تسلا با مشخصاتی مشابه با پایگاه داده iSeg 2017 تصویربرداری شده‌اند. تصاویر تست از مراکز مختلفی تهیه شده‌اند که مشخصات تصویربرداری متفاوتی با داده‌های آموزش دارند. در واقع، مجموعه داده تست از سه مرکز BCP، دانشگاه استنفورد و دانشگاه اموری تهیه شده است که مشخصات آن در جدول (۳) شده است.

### ۳-۲- معیارهای ارزیابی

برای ارزیابی نتایج روش پیشنهادی از معیارهای مختلفی استفاده می‌شود. هدف اصلی از معیارهای ارائه شده، مقایسه عملکرد و دقت ناحیه‌بندی توسط روش پیشنهادی با نواحی برچسب شده دستی است. سه معیار به نام های دایس، فاصله هاسدورف<sup>۱</sup> و فاصله متوسط سطح<sup>۲</sup> به کار گرفته شده، که طبق روابط زیر تعریف می‌شوند.

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

$$HD(C, D) = \max(h(C, D), h(D, C)) \quad (2)$$

$$h(C, D) = \max_{c \in C} \max_{d \in D} \|c - d\| \quad (3)$$

$$ASD = \frac{1}{2} \left( \frac{\sum_{V_i \in S_A} \min_{V_j \in S_B} d(V_i, V_j)}{\sum_{V_i \in S_A} 1} + \frac{\sum_{V_j \in S_B} \min_{V_i \in S_A} d(V_j, V_i)}{\sum_{V_j \in S_B} 1} \right) \quad (4)$$

رابطه (۱)، مربوط به معیار دایس بوده و در آن، A و B نشان دهنده برچسب‌های باینری دستی و به دست آمده از روش پیشنهادی هستند. عملگر |.| تعداد پیکسل‌های مثبت در تصویر باینری را نشان می‌دهد و  $|A \cap B|$  تعداد پیکسل‌های مثبت مشترک در دو تصویر برچسب و ناحیه‌بندی شده روش پیشنهادی است. در (۲)، C و D دو مجموعه رأس<sup>۳</sup> هستند که به ترتیب به صورت دستی و محاسباتی برای یک کلاس بافت مشخص شده‌اند. رأس به هر یک از نقاط زاویه‌ای روی مرز نواحی مغز اطلاق می‌گردد. در این رابطه،  $h(C, D)$  طبق (۳) به دست می‌آید که معرف معیار هاسدورف است. رابطه (۴) نیز نشان‌دهنده فاصله متوسط سطح است.  $S_A$  سطح نقشه برچسب است و  $S_B$  سطح نقشه به دست آمده توسط روش پیشنهادی است. همچنین  $d(V_i, V_j)$  فاصله اقلیدسی از رأس  $V_i$  تا  $V_j$  را نشان می‌دهد. بهترین روش، روشی است که حداکثر دایس و حداقل HD و ASD را نتیجه بدهد.

<sup>4</sup> Mean Square Error (MSE)

<sup>1</sup> Hausdorff Distance (HD)

<sup>2</sup> Average Surface Distance (ASD)

<sup>3</sup> Vertex



$$L = y_{true} \log(p) + (1 - y_{true}) \log(1 - p) \quad (5)$$

از روش بهینه سازی آدم برای بهینه کردن تابع هزینه استفاده شده است. پارامترهای آموزش مدل CNN پیشنهادی در جدول (5) نشان داده شده است. نتایج به دست آمده توسط روش پیشنهادی بر روی داده‌های تست پایگاه‌های داده iSeg 2017 و iSeg 2019 در جداول (6-7) به صورت مجزا برای هر تصویر ذکر شده‌اند. نتایج به دست آمده بر اساس معیارهای ارزیابی به طور مجزا برای هر یک از بافت‌های مغزی ذکر شده است. همچنین انحراف معیار مربوط به هر سه معیار نیز محاسبه شده است. همانطور که مشاهده می‌شود، روش پیشنهادی توانسته ناحیه سفید، خاکستری و مایع مغز را به ترتیب با دایس 0/1873، 0/898 و 0/937 و برای تصاویر iSeg-2017 و 0/767، 0/749 و 0/774 برای تصاویر iSeg-2019 ناحیه بندی کند. همچنین نتایج مربوط به معیار ارزیابی هاسدروف در نواحی سفید، خاکستری و مایع مغزی نخاعی به ترتیب برابر 7/16 و 7/44 و 10/0 در داده iSeg 2017 و 8/57 و 8/35 و 11/88 به ازای داده iSeg 2019 می‌باشد، که نشان از تفکیک خوب این نواحی است. معیار مربوط به فاصله متوسط سطح نیز با مقدار به دست آمده که در جداول (6-7) بیان شده است، نشان از کارایی مناسب این روش در ناحیه بندی تصاویر مغزی دارد.


در جداول (8-9) نتایج روش پیشنهادی با برخی از روش‌های موجود در [26 و 27] مقایسه شده است. ارزیابی‌ها نشان می‌دهد که روش پیشنهادی در مقایسه با روش‌های موجود با دقت خوبی توانسته ناحیه بندی را انجام دهد. در واقع پیش‌پردازش انجام شده بر روی تصاویر MRI و همچنین استفاده از روش‌های افزونی داده این امکان را به روش پیشنهادی داده که بتواند نتایج خوبی را حتی به ازای پایگاه داده تست iSeg-2019 که شامل تصاویری با پروتکل‌های تصویربرداری متنوع هست، به دست آورد.

#### 4- نتیجه گیری


در این مقاله، یک روش خودکار برای ناحیه بندی تصاویر MRI مغز نوزادان مبتنی بر شبکه‌های پیچشی ارائه شد. در روش پیشنهادی برای غلبه بر چالش شباهت توزیع شدت روشنایی در بافت‌های ماده خاکستری و ماده سفید، یک روش پیش‌پردازش مبتنی بر شبکه پیچشی U-net ارائه شد که به طور مناسبی تفکیک مناسبی بین بافت‌های مغز ایجاد کرد. در ادامه یک شبکه عصبی پیچشی برای ناحیه بندی تصاویر پیش‌پردازش شده و به دست آوردن نواحی بافت‌های مغز ارائه شد. برای ناحیه بندی مقاوم در برابر تصاویر تهیه شده از روش‌های افزایش داده استفاده شد. نتایج به دست آمده نشان‌دهنده کارایی مناسب روش پیشنهادی در ناحیه بندی تصاویر مغز پایگاه‌های داده استاندارد است به طوری که برای پایگاه داده iSeg-2017 به ترتیب دایس 0/898 و 0/937 و برای پایگاه داده iSeg-2019 به ترتیب دایس 0/767، 0/749 و 0/774 برای نواحی سفید، خاکستری و مایع مغزی به دست آمده است.

- **افزایش کنتراست:** توسط این روش، یک نسخه از تصویر هر برش ایجاد می‌شود که در آن کنتراست تصویر بهبود یافته است. برای افزایش کنتراست از روش متعادل سازی کنتراست استفاده شده است. با انجام روش‌های ذکر شده، پایگاه داده آموزش به طور موثری بزرگتر می‌شود که این به آموزش بهتر مدل نیز کمک می‌کند. در شکل (7)، برخی از نسخه‌های به دست آمده از روش‌های مختلف افزایش داده نشان داده شده است.

از آنجا که دو مدالیته T1 و T2 در اختیار است، دو مدل U-net آموزش داده می‌شود تا پیش‌پردازش برای هر مدالیته به طور مجزا انجام شود. با آموزش مدل U-net توسط داده آموزش افزایش یافته، می‌توان از آن برای انجام پیش‌پردازش بر روی تصاویر تست استفاده کرد. در شکل (8)، چند نمونه از تصاویر پیش‌پردازش شده توسط روش پیشنهادی به ازای پایگاه داده iSeg 2017 و iSeg 2019 ارائه شده است.



شکل (7): روش‌های مختلف افزایش داده استفاده شده برای آموزش مدل u-net: (الف) تصویر برش اصلی، (ب) افزایش روشنایی توسط تابع گاما، (ج) کاهش شدت روشنایی توسط تابع گاما، (د) تصویر با کنتراست افزایش یافته، (ه) انعکاس افقی، (و) انعکاس عمودی، (ز) جابجایی به سمت بالا، (ح) جابجایی به سمت پایین و چپ



شکل (8): نتایج پیش‌پردازش به دست آمده توسط روش پیشنهادی: (الف) تصویر T2، (ب) تصویر پیش‌پردازش شده T2، (ج) تصویر پیش‌پردازش شده T1، (د) تصویر T1

جدول ۸: مقایسه نتایج به دست آمده توسط روش پیشنهادی با سایر

**روش‌ها برای پایگاه داده iSeg 2017**

روش	بافت سفید (WM)		بافت خاکستری (GM)		مایع مغز (CSF)	
	ASD	Dice	ASD	Dice	ASD	Dice
پیشنهادی	<b>0.478</b>	<b>0.873</b>	<b>0.406</b>	<b>0.898</b>	0.184	<b>0.937</b>
Uoff-Bioluming	0.517	0.870	0.429	0.895	0.162	<b>0.94</b>
BIGS2	0.496	0.871	0.409	0.893	<b>0.144</b>	<b>0.949</b>
LRDE	0.521	0.864	0.451	0.888	0.197	0.929
Authman	0.564	0.846	0.495	0.872	0.224	0.917

جدول ۹: مقایسه نتایج به دست آمده توسط روش پیشنهادی با سایر

**روش‌ها برای پایگاه داده iSeg 2019**

روش	بافت سفید (WM)		بافت خاکستری (GM)		مایع مغز (CSF)	
	ASD	Dice	ASD	Dice	ASD	Dice
پیشنهادی	<b>0.803</b>	<b>0.767</b>	<b>0.704</b>	<b>0.749</b>	<b>0.696</b>	<b>0.774</b>
MASI	1.33	0.67	0.429	0.895	0.162	0.94

### مراجع

- [1] G. Li, et al., *Mapping Region-Specific Longitudinal Cortical Surface Expansion from Birth to 2 Years of Age, Cerebral Cortex*, vol. 23, pp. 2724-2733, Nov 2013.
- [2] L. Wang, et al., *Segmentation of Neonatal Brain MR Images Using Patch-Driven Level Sets*, NeuroImage, vol. 84, pp. 141-158, Jan 1, 2014.
- [3] L. Wang, et al., *Links: Learning-Based Multi-Source Integration Framework for Segmentation of Infant Brain Images*, NeuroImage, vol. 108, pp. 160-72, Mar 2015.
- [4] F. Shi, et al., *Neonatal Atlas Construction Using Sparse Representation*, Human Brain Mapping, vol. 35, pp. 4663-4677, Sep 2014.
- [5] F. Shi, et al., *Construction of Multi-Region-Multi-Reference Atlases for Neonatal Brain MRI Segmentation*, NeuroImage, vol. 51, pp. 684-693, Jun 2010.
- [6] Devi, C. N., et al., *Automatic segmentation of infant brain MR images: With special reference to myelinated white matter*, Biocybernetics and Biomedical Engineering, vol. 37, no. 1, pp. 143-158, 2017.
- [7] G. Li, et al., *Computational Neuroanatomy of Baby Brains: A Review*, NeuroImage, vol. 185, pp. 906-925, 2018.
- [8] George, M. M., et al., *A view on atlas-based neonatal brain MRI segmentation*. ICTMI 2017, pp. 199-214, 2019.
- [9] Mostapha, M. et al., *Role of deep learning in infant brain MRI analysis. Magnetic resonance imaging*, vol. 64, pp.171-189, 2019.
- [10] Wu, Z., et al, *Construction of 4D infant cortical surface atlases with sharp folding patterns via spherical patch-based group-wise sparse representation*, Human brain mapping, vol. 40, no. 13, pp. 3860-3880, 2019.
- [11] Iclănzan, D., et al., *The role of atlases and multi-atlases in brain tissue segmentation based on multispectral magnetic resonance image data*. In 2021 IEEE AFRICAN, pp. 1-6, 2021.
- [12] Wang, J., et al., *Multi-atlas segmentation of subcortical brain structures via the AutoSeg software pipeline*, Frontiers in neuroinformatics, vol. 8, pp. 7-15, 2014.
- [13] Dong, P., et al., *Multi-atlas and multi-modal hippocampus segmentation for infant MR brain images by propagating anatomical labels on hypergraph*, In International

جدول ۵: پارامترهای آموزش مدل CNN

پارامتر	مقدار
نرخ یادگیری	۰/۰۱
تعداد تکرار	۱۰۰
mini-batch	۲۵۶
ضریب کاهش نرخ یادگیری	۰/۸
تابع هزینه	آنتروپی باینری

جدول ۶: نتایج به دست آمده توسط روش پیشنهادی برای پایگاه داده

**iSeg 2017**

تصویر تست	بافت سفید (WM)			بافت خاکستری (GM)			مایع مغز (CSF)		
	ASD	MHD	Dice	ASD	MHD	Dice	ASD	MHD	Dice
11	0.411	7.87	0.887	0.339	6.40	0.912	0.139	6.48	0.948
12	0.535	5.38	0.840	0.440	5	0.882	0.169	7.07	0.936
13	0.467	8.12	0.885	0.394	8.06	0.907	0.172	11.9	0.943
14	0.457	6.16	0.878	0.417	8.24	0.898	0.199	9	0.925
15	0.443	6.32	0.884	0.369	6.40	0.912	0.137	7.874	0.948
16	0.473	8.77	0.884	0.403	7.87	0.896	0.168	11	0.94
17	0.412	6.48	0.887	0.353	7.21	0.904	0.152	8.124	0.943
18	0.460	7.68	0.879	0.379	8.06	0.900	0.149	9.48	0.948
19	0.465	7.21	0.885	0.385	7.34	0.900	0.151	9	0.944
20	0.610	8.30	0.832	0.506	7.28	0.879	0.244	13.9	0.927
21	0.464	6.16	0.876	0.384	6.70	0.902	0.1615	9.27	0.939
22	0.506	7.07	0.872	0.447	7	0.902	0.189	10.8	0.926
23	0.510	7.61	0.866	0.467	11.2	0.887	0.368	16.03	0.915
<b>میانگین</b>	<b>0.478</b>	<b>7.16</b>	<b>0.873</b>	<b>0.406</b>	<b>7.44</b>	<b>0.898</b>	<b>0.184</b>	<b>10.00</b>	<b>0.937</b>
<b>انحراف معیار</b>	<b>0.053</b>	<b>1.00</b>	<b>0.018</b>	<b>0.047</b>	<b>1.43</b>	<b>0.010</b>	<b>0.062</b>	<b>2.722</b>	<b>0.010</b>

جدول ۷: نتایج به دست آمده توسط روش پیشنهادی برای پایگاه داده

**iSeg 2019**

تصویر تست	بافت سفید (WM)			بافت خاکستری (GM)			مایع مغز (CSF)		
	ASD	MHD	Dice	ASD	MHD	Dice	ASD	MHD	Dice
24	0.772	7.810	0.780	0.674	7.07	0.775	0.595	10.77	0.813
25	0.762	8.774	0.773	0.661	6.32	0.772	0.556	11.66	0.799
26	0.735	7.141	0.804	0.674	7.34	0.782	0.672	11.53	0.728
27	0.702	6.70	0.797	0.635	7.81	0.778	0.571	10.24	0.801
28	0.699	8.36	0.807	0.635	9.27	0.791	0.559	12.36	0.813
29	0.708	8	0.820	0.653	8.48	0.778	0.601	9.848	0.799
30	1.067	9.43	0.675	0.917	9	0.646	1.421	19.26	0.620
31	0.854	8.60	0.766	0.758	9.16	0.728	0.817	13.56	0.778
32	0.869	9.64	0.735	0.787	8.18	0.698	1.015	13.03	0.701
33	0.730	9.69	0.797	0.714	7.87	0.739	0.868	13.30	0.746
34	0.835	10.72	0.760	0.781	8.77	0.710	1.039	14.17	0.707
35	0.865	9.53	0.735	0.698	8.06	0.757	0.453	10.05	0.845
36	0.898	8.77	0.727	0.725	8.12	0.749	0.458	10.81	0.845
37	0.783	7.87	0.758	0.652	8.06	0.765	0.485	10.19	0.782
38	0.807	11.18	0.765	0.665	13.60	0.742	0.544	9.38	0.786
39	0.767	7.81	0.769	0.634	6.55	0.767	0.471	9.9	0.825
<b>میانگین</b>	<b>0.803</b>	<b>8.75</b>	<b>0.767</b>	<b>0.704</b>	<b>8.35</b>	<b>0.749</b>	<b>0.696</b>	<b>11.88</b>	<b>0.774</b>
<b>انحراف معیار</b>	<b>0.095</b>	<b>1.22</b>	<b>0.036</b>	<b>0.075</b>	<b>1.64</b>	<b>0.038</b>	<b>0.271</b>	<b>2.47</b>	<b>0.060</b>



- [29] Good, I. J. *Rational Decisions*. Journal of the Royal Statistical Society. Series B (Methodological), vol. 14, no. 1, pp. 107–114, 1952.
- Workshop on Patch-based Techniques in Medical Imaging Springer, pp. 188-196, 2015.
- [14] Puonti, O., Iglesias, J.E. and Van Leemput, K., *Fast and sequence-adaptive whole-brain segmentation using parametric Bayesian modeling*. NeuroImage, Vol. 143, pp. 235-249, 2016.
- [15] Makropoulos, A., Counsell, S.J., Rueckert, D., *A review on automatic fetal and neonatal brain MRI segmentation*. NeuroImage, Vol. 170, pp. 231-248, 2018.
- [16] Guo, Y., Wu, Z. and Shen, D., *Learning longitudinal classification-regression model for infant hippocampus segmentation*. Neurocomputing, Vol. 391, pp.191-198, 2020.
- [17] Dolz, J., Desrosiers, C., Wang, L., Yuan, J., Shen, D. and Ayed, I.B., *Deep CNN ensembles and suggestive annotations for infant brain MRI segmentation*. Computerized Medical Imaging and Graphics, Vol. 79, p.101660, 2020.
- [18] Bui, T.D., Shin, J. and Moon, T., *Skip-connected 3D DenseNet for volumetric infant brain MRI segmentation*. Biomedical Signal Processing and Control, 54, p.101613, 2019.
- [19] Chen, Y., Qin, Y., Jin, Z., Fan, Z. and Cai, M., *A Triple Residual Multiscale Fully Convolutional Network Model for Multimodal Infant Brain MRI Segmentation*. KSII Transactions on Internet and Information Systems (TIIS), Vol. 14, pp.962-975, 2020.
- [20] Qamar, S., Jin, H., Zheng, R., Ahmad, P. and Usama, M., *A variant form of 3D-UNet for infant brain segmentation*. Future Generation Computer Systems, Vol. 108, pp.613-623, 2020.
- [21] Karayegen, G. and Aksahin, M.F., *Brain tumor prediction on MR images with semantic segmentation by using deep learning network and 3D imaging of tumor region*. Biomedical Signal Processing and Control, Vol. 66, p.102458, 2021.
- [22] Pasban, S., Mohamadzadeh, S., Zeraatkar-Moghaddam, J. and Shafiei, A.K., *Infant brain segmentation based on a combination of VGG-16 and U-Net deep neural networks*. IET Image Processing, Vol. 14, pp.4756-4765, 2021.
- [23] Ding, W., Abdel-Basset, M., Hawash, H., & Pedrycz, W. (2022). Multimodal infant brain segmentation by fuzzy-informed deep learning. *IEEE Transactions on Fuzzy Systems*, 30(4), 1088-1101
- [24] Saladi, S., Karuna, Y., Koppu, S., Reddy, G. R., Mohan, S., Mallik, S., & Qin, H. (2023). Segmentation and analysis emphasizing neonatal MRI brain images using machine learning techniques. *Mathematics*, 11(2), 285.
- [25] Chen, L., Wu, Z., Zhao, F., Wang, Y., Lin, W., Wang, L., & Li, G. (2023). An attention-based context-informed deep framework for infant brain subcortical segmentation. *Neuroimage*, 269, 119931.
- [26] Wang, L., Nie, D., Li, G., Puybureau, É., Dolz, J., Zhang, Q., Wang, F., Xia, J., Wu, Z., Chen, J.W. and Thung, K.H., *Benchmark on automatic six-month-old infant brain segmentation algorithms: the iSeg-2017 challenge*. IEEE transactions on medical imaging, Vol. 38, pp.2219-2230, 2019.
- [27] Sun, Yue, Kun Gao, Zhengwang Wu, Guannan Li, Xiaopeng Zong, Zhihao Lei, Ying Wei. *Multi-site infant brain segmentation algorithms: The iSeg-2019 Challenge*. IEEE Transactions on Medical Imaging Vol. 5, pp. 1363-1376, 2021.
- [28] Diederik P. Kingma and Jimmy Lei Ba. *Adam: A method for stochastic optimization*. arXiv:1412.6980v9, 2014.



## تکنیک‌های تشخیص جعل کپی-جابجایی مبتنی بر روش‌های سنتی در

### تصاویر دیجیتال

مریم عطائی قهفرخی<sup>۱</sup>، آذر محمودزاده<sup>۲\*</sup>

۱- گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران  
mari.attaie1994@gmail.com

۲- گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران  
azar\_mahmoodzadeh@yahoo.com

**چکیده:** جعل تصویر، یکی از زمینه‌های بسیار پر کاربرد در پردازش تصویر است که به صورت گسترده مورد توجه و مطالعه پژوهشگران قرار گرفته است. انواع مختلفی برای جعل تصویر دیجیتال موجود است که جعل کپی-جابجایی یکی از نمونه‌های رایج است که تشخیص این نوع جعل بسیار حائز اهمیت است. در این مقاله، ضمن معرفی مفاهیم جعل کپی-جابجایی تصویر، به بررسی مراحل، دسته‌بندی روش‌های تشخیص و سوگیری تحقیقات در این زمینه پرداخته شده است. این مقاله می‌تواند راهگشای پژوهشگران پردازش تصویر در فرآیند تشخیص جعل کپی-جابجایی باشد. اهتمام نویسندگان بر این بوده است که همه جنبه‌های این فرآیند مورد کاوش قرار گیرد.

**واژه‌های کلیدی:** جعل کپی-جابجایی تصویر، شناسایی جعل، پردازش تصویر، تصویر دیجیتال.

## Copy-Move Forgery Detection Techniques based on Traditional Methods in Digital Images

Maryam Attaie Gahfarkhi<sup>1</sup>, Azar Mahmoodzadeh<sup>2\*</sup>

<sup>1</sup> Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
mari.attaie1994@gmail.com

<sup>2</sup> Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
[Azar.mahmoodzadeh@iau.ac.ir](mailto:Azar.mahmoodzadeh@iau.ac.ir)

### Abstract:

Image forgery is one of the most widely used fields in image processing, which has been widely studied and studied by researchers. There are different types of digital image forgery, copy-move forgery is one of the common examples, and it is very important to recognize this type of forgery. In this review article, while introducing the concepts of copy-move image forgery, the steps, classification of detection methods and research bias in this field have been discussed. This article can open the way for image processing researchers in the process of detecting copy-move forgery. The authors' effort has been to explore all aspects of this process.

**Keywords:** Copy-Move Image Forgery, Forgery Detection, Image Processing, Digital Image.

DOI: 00.00000/0000

تاریخ چاپ مقاله: ۱۴۰۲/۰۳/۱۲

تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۱۱

نوع مقاله: پژوهشی

تاریخ ارسال مقاله: ۱۴۰۲/۰۱/۰۵

## ۱- مقدمه

سازمان‌دهی مقاله به این صورت است که در بخش دوم به بررسی انواع جعل تصاویر دیجیتال، در بخش سوم به شرح مراحل تشخیص جعل کپی-جابجایی و در بخش چهارم، به بررسی روش‌های تشخیص جعل کپی-جابجایی پرداخته می‌شود. دیتابیس‌های رایج، معیارهای ارزیابی، و رویکردهای جدید به ترتیب در بخش پنجم، ششم، و هفتم، و در نهایت به جمع‌بندی در بخش هشتم پرداخته می‌شود.

## ۲- انواع جعل تصاویر دیجیتال

جعل تصاویر دیجیتال را به طور کلی می‌توان به پنج دسته، جعل کپی-جابجایی تصویر، پیوند زدن تصویر، روتوش کردن تصویر، مورفولوژی و بهبود تصاویر تقسیم کرد (شکل ۱) [۶]. جعل کپی-جابجایی تصویر، یکی از رایج‌ترین انواع جعل تصاویر دیجیتال است [۷].

## ۳- مراحل تشخیص جعل کپی-جابجایی

تشخیص جعل کپی-جابجایی به طور کلی از پنج مرحله اصلی تشکیل شده است که این مراحل در همه روش‌های تشخیص جعل کپی-جابجایی تقریباً یکسان می‌باشد [۷] که در ادامه هر یک از این مراحل به طور مختصر توضیح داده می‌شود.

**پیش‌پردازش<sup>۱</sup>:** در هر گونه از روش‌های تشخیص جعل کپی-جابجایی، مرحله پیش‌پردازش تصویر وجود دارد که شامل عملیاتی مانند چیدن<sup>۲</sup> و تبدیل تصویر رنگی به خاکستری می‌باشد.

**استخراج ویژگی<sup>۳</sup>:** در هر گونه از روش‌های تشخیص جعل کپی-جابجایی، ویژگی‌های از مناطقی از تصویر که آنتروپی بالا<sup>۴</sup> دارند شناسایی و استخراج می‌شوند.

**تطبیق<sup>۵</sup>:** بردارهای ویژگی استخراج شده در هر روش، برای یافتن مناطق جعل کپی‌شده تطبیق داده می‌شود. شباهت بالا بین دو توصیف‌گر ویژگی به عنوان یک نشانه برای منطقه کپی شده است.

**فیلتر کردن<sup>۶</sup>:** فیلترینگ جهت کاهش تطبیق‌های اشتباه استفاده می‌شود. پیکسل‌های همسایه اطراف نواحی جعل معمولاً شدت روشنایی مشابه دارند که می‌تواند منجر به تطبیق‌های اشتباه و در نهایت تشخیص جعل اشتباه شود.

## ۴- بررسی روش‌های تشخیص جعل کپی جابجایی

روش‌های گوناگونی جهت تشخیص جعل کپی-جابجایی تصویر وجود دارد که به طور کلی می‌توان به دو دسته، تشخیص جعل مبتنی بر روش‌های سنتی و روش‌های مبتنی بر یادگیری ماشین دسته‌بندی کرد [۹، ۱۰]. روش‌های سنتی به دو دسته، روش‌های مبتنی بر نقاط کلیدی و روش‌های تشخیص جعل مبتنی بر بلوک می‌باشد.

محتوای دیجیتال همچون تصاویر، ویدئوها و فایل‌های صوتی، هر روز در شبکه‌های اجتماعی به طور گسترده استفاده می‌شوند که تصاویر، محبوب‌ترین منابع اشتراکی می‌باشند. در سال‌های اخیر با توسعه نرم افزارهای پیشرفته پردازش تصویر، تصاویر را می‌توان به راحتی بدون باقی ماندن ردپای محسوس جعل کرد. بنابراین، شناسایی خودکار تصاویر دستکاری شده برای کاربران عملی دشوار است [۱، ۲]. در نتیجه ابزارهای تشخیص جعل تصاویر دیجیتالی از اهمیت ویژه‌ای برخوردار است.

روش‌های جعل به‌طور کلی به دو دسته عمده، روش‌های فعال و روش‌های غیرفعال تقسیم می‌شوند [۳]. روش‌های فعال، ویژگی‌های مبهم را از تصاویر بازمی‌کنند. روش‌هایی که از کیفیت ذاتی تصویر برای شناسایی جعلیات استفاده می‌کنند، شامل تکنیک‌های غیرفعال هستند که به دنبال کشف ناهنجاری‌ها در متغیرهای آماری، تفاوت‌ها در رنگ و بافت، و فشرده‌سازی مضاعف JPEG هستند. اخیراً روش‌های غیرفعال به طور گسترده استفاده می‌شود.

جعل کپی-جابجایی تصویر، یکی از روش‌های غیرفعال است که در این نوع جعل، بخش‌هایی (شی یا فرد) از تصویر کپی می‌شود و به منطقه دیگری از همان تصویر یا تصویر دیگر و با یا بدون دستکاری (تبدیل هندسی) گذاشته می‌شود. این روش یکی از متداول‌ترین و ساده‌ترین نوع جعل می‌باشد که در سال‌های اخیر مورد توجه محققان زیادی قرار گرفته است که این نشان دهنده اهمیت به این موضوع می‌باشد. با این حال، تاکنون مقاله مروری به زبان فارسی ارائه نشده است. همچنین مقالات انگلیسی اندکی در این زمینه وجود دارد که عمدتاً به بررسی تعداد معدودی از روش‌های تشخیص جعل کپی-جابجایی پرداخته‌اند [۱-۳]. از طرف دیگر مقالات مروری که اخیراً چاپ شده فقط به نوع خاصی از روش‌های تشخیص جعل کپی-جابجایی پرداخته‌اند [۴-۶]. اهمیت و کاربرد روزافزون تشخیص جعل کپی جابجایی نشان می‌دهد که هر پنج سال یک‌بار باید یک مقاله مروری در این زمینه نوشته شود تا بتواند دانشمندان در جهت ارتقا عملکرد فرآیند تشخیص خطای کپی-جابجایی راهنمایی کند. چنین مقالاتی می‌توانند راهگشای محققان در انتخاب مناسب و بهره‌گیری از این الگوریتم‌ها در کاربردهای مورد علاقه‌شان باشد. موارد ذکر شده، انگیزه بخش نگارش این مقاله در خصوص تشخیص جعل کپی-جابجایی بوده است. هدف این مقاله، بررسی انواع جعل، تشریح مراحل تشخیص جعل کپی-جابجایی تصویر، بررسی روش‌های تشخیص جعل کپی-جابجایی تصویر، تشریح دیتابیس موجود و معیارهای ارزیابی پرداخته می‌شود.

<sup>4</sup>High Entropy

<sup>5</sup>Matching

<sup>6</sup>Filtering

<sup>1</sup>Pre-processing

<sup>2</sup>Cropping

<sup>3</sup>Feature Extraction



#### ۴-۱- تشخیص جعل کپی-جابجایی مبتنی بر نقاط

##### کلیدی

در روش تشخیص جعل کپی-جابجایی مبتنی بر نقاط کلیدی، نیازی به تقسیم تصویر به بلوک نیست. در این روش ها ابتدا نقاط ویژگی شناسایی می شوند. سپس برای هر یک از ویژگی های شناسایی شده، توصیفگر ایجاد می شود و در نهایت فرآیند تطبیق برای شناسایی مناطق جعل انجام می شود [۸]. در این روش ها، تکنیک های استخراج ویژگی و تطبیق از مراحل مهم می باشد [۹]. در ادامه، به شرح چند الگوریتم مهم رایج استخراج ویژگی و سپس روش های مهم تطبیق پرداخته می شود.

#### ۴-۱-۱- بررسی الگوریتم های استخراج ویژگی در روش -


##### های تشخیص جعل کپی-جابجایی مبتنی بر نقاط کلیدی

در این بخش به بررسی الگوریتم های رایج استخراج ویژگی همچون تبدیل ویژگی مقیاس ثابت و الگوریتم SURF، الگوریتم MIFT، الگوریتم ORB، الگوریتم KAZE و الگوریتم A-KAZE پرداخته می شود.

##### • الگوریتم SIFT

الگوریتم تبدیل ویژگی مقیاس ثابت در سال ۲۰۰۴ توسط لاوو معرفی شد [۱۰]. ویژگی های شناسایی شده در این الگوریتم، نسبت به تغییرات مقیاس و چرخش ثلثت هستند و نسبت به تغییر زاویه و تغییرات شدت روشنایی مقاوم هستند. در ادامه به بررسی الگوریتم SIFT و نسخه های بهبودیافته آن در جعل کپی-جابجایی استفاده شده پرداخته می شود.

در [۱۱] از الگوریتم SIFT و خوشه بندی سلسله مرتبه ای<sup>۱</sup> به ترتیب جهت شناسایی و تطبیق ویژگی ها برای شناسایی نواحی چندگانه جعل استفاده شده است. در [۱۲] از الگوریتم SIFT و SURF جهت شناسایی ویژگی ها و از فاصله اقلیدوسی برای تطبیق ویژگی ها بهره گرفته شد. در [۱۳] ابتدا از الگوریتم SIFT جهت شناسایی ویژگی ها و سپس از روش تطبیق جدیدی بر اساس الگوریتم SIFT جهت تطبیق نواحی جعل استفاده شده است. این روش نسبت به روش های کلاسیک دیگر [۱۴، ۱۵] عملکرد مناسب تری از نظر زمان اجرا و نرخ مثبت درست<sup>۲</sup> و نرخ مثبت اشتباه<sup>۳</sup> دارد. در [۱۶] از الگوریتم RKEM-SIFT و خوشه بندی سلسله مرتبه ای به ترتیب جهت شناسایی و تطبیق ویژگی ها استفاده شده که این روش برای شناسایی نواحی جعل به طور موثر عمل می کند. در [۱۷] از الگوریتم SIFT، گشتاور ثابت و الگوریتم رشد ناحیه به ترتیب جهت شناسایی، تطبیق ویژگی ها و شناسایی نواحی جعل کپی-جابجایی استفاده شده است. این روش نسبت به روش های [۱۳، ۱۸] دقت عملکرد مناسب تری دارد. در [۱۹] به مقایسه



شکل (۱): انواع جعل تصاویر دیجیتال [۶] (الف) جعل کپی-جابجایی (تصویر سمت چپ: تصویر معتبر، تصویر سمت راست: تصویر جعل کپی-جابجایی)، (ب) پیوند زدن (تصاویر سمت چپ و مرکز: تصاویر معتبر، تصویر سمت راست: تصویر پیوند)، (ج) مورفولوژی (تصاویر سمت چپ و مرکز: تصاویر معتبر، تصویر سمت راست: مورفولوژی)، (د) روتوش تصویر (تصاویر سمت چپ: تصویر معتبر، تصویر سمت راست: تویر روتوش شده)، (ه) بهبود تصویر (تصاویر سمت چپ: تصویر معتبر، تصاویر سمت راست: تصویر بهبود یافته از جهت تغییر رنگ پس زمینه)

<sup>3</sup> False-Positive Rate

<sup>1</sup> Hierarchical Clustering

<sup>2</sup> True-Positive Rate



لگوریتم های SIFT، SURF<sup>1</sup> و HOG در جعل کپی-جابجایی پرداخته شد که نشان می‌دهد الگوریتم SIFT نسبت به دو الگوریتم دیگر از دقت بالاتری برخوردار است.

#### • الگوریتم SURF

SURF یک آشکارساز ویژگی محلی مقاوم است که اولین بار توسط هربرت بای<sup>2</sup> و همکارانش در سال ۲۰۰۶ ارائه شده است [۲۰] که می‌تواند در کارهای بینایی ماشین مانند بازشناسی یا بازیابی شیء استفاده شود. SURF از اندازه‌گیری سریع ماتریس هسیان<sup>3</sup> برای آشکارساز و توصیف‌گر مبتنی بر توزیع استفاده می‌کند. SURF مشابه SIFT نسبت به چرخش و مقیاس ثابت است، اما در یک زمان ثابت، SURF می‌تواند سریع‌تر عمل کند. در ادامه به بررسی الگوریتم SURF و نسخه‌های بهبودیافته آن در جعل کپی-جابجایی استفاده شده پرداخته می‌شود.

در [۲۱] از الگوریتم SURF و رویکرد نزدیکترین همسایه<sup>4</sup> جهت شناسایی نقاط کلیدی و تطبیق میان آنها استفاده می‌شود که این روش برای شناسایی نواحی جعل چندگانه با تغییرات چرخش و محوشدگی مناسب است. در [۲۲]، رویکرد جدیدی براساس الگوریتم SURF و PCET جهت شناسایی نواحی جعل کپی-جابجایی ارائه شده است. در این روش، ابتدا تصویر به بلوک‌های غیر هم‌پوشان تقسیم می‌شوند و سپس نقاط کلیدی توسط الگوریتم SURF از هر بلوک استخراج می‌شوند و در نهایت با توصیف‌گر PCET و تطبیق 2gNN جهت شناسایی نواحی جعل کپی-جابجایی استفاده می‌شود. در [۲۳]، روش جدیدی جهت جعل کپی-جابجایی تصویر پیشنهاد شده است. ابتدا، الگوریتم SURF و BRISK به ترتیب جهت شناسایی ویژگی‌ها و توصیف‌گرها استفاده شده است و سپس الگوریتم تطبیق 2NN جهت تطبیق به‌کار گرفته شده است. این رویکرد در کاهش نرخ شناسایی اشتباه موثر است. در [۲۴]، از الگوریتم SURF جهت توصیف نقاط کلیدی استفاده شده است که سبب کاهش زمان اجرا و افزایش دقت در فرآیند تشخیص جعل کپی-جابجایی شده است. در [۲۵]، الگوریتم SURF جهت شناسایی ویژگی‌ها در فرآیند تشخیص جعل کپی-جابجایی به‌کار گرفته شده است. این روش سبب به‌طور موثر نواحی جعل با تغییرات مقیاس، چرخش و محوشدگی را شناسایی می‌کند.

#### • الگوریتم FAST

الگوریتم FAST<sup>5</sup> برای شناسایی گوشه در تصویر توسط روستن<sup>6</sup> در سال ۲۰۰۸ معرفی شد [۲۶]. این الگوریتم نسبت به تغییرات چرخش ثابت می‌باشد و نسبت به تغییرات جزئی مقیاس پایداری مناسبی دارد. در ادامه به شرح جزئیات این الگوریتم پرداخته می‌شود.

۱- یک پنجره دایره‌ای با ۱۶ پیکسل اطراف هر پیکسل مورد بررسی در نظر گرفته می‌شود.

۲- یک مقدار آستانه شدت روشنایی (T) در نظر گرفته می‌شود.  
۳- ابتدا مقدار شدت روشنایی پیکسل های ۱ و ۵ و ۹ و ۱۳ نسبت به آستانه مورد بررسی قرار خواهد گرفت.

۴- اگر حداقل سه تا از چهار پیکسل  $I_1, I_5, I_9, I_{13}$  مقدار شدت روشنایی آن بالاتر یا پایین‌تر از آستانه نباشد، در این مورد پیکسل مورد نظر به عنوان گوشه در نظر گرفته نمی‌شود. در غیر این صورت اگر حداقل سه تا از پیکسل‌ها بالاتر یا پایین‌تر از آستانه باشد، پس برای ۱۲ پیکسل دیگر مقدار شدت روشنایی آن نسبت به آستانه بررسی می‌شود.

۵- این فرآیند برای همه‌ی پیکسل‌ها در تصویر مورد بررسی قرار خواهد گرفت.

در [۲۷]، از الگوریتم SIFT و FAST جهت شناسایی نقاط کلیدی در نواحی جعل کپی-جابجایی استفاده شده است. الگوریتم SIFT برای شناسایی نقاط کلیدی در مناطق هموار و الگوریتم FAST برای شناسایی نقاط کلیدی در مناطق بافت به‌کار گرفته شده است که این روش از دقت بهتری و پیچیدگی محاسباتی کمتری برخوردار است.

#### • الگوریتم ORB

الگوریتم ORB از شناساگر FAST و توصیف‌گر BRIEF تشکیل شده است که نقاط کلیدی FAST، جهت ندارد. الگوریتم FAST و BRIEF هم عملکرد خوب و هم هزینه محاسباتی کمتری دارد. الگوریتم ORB نسبت به تغییرات چرخش ثابت و نویز مقاوم است. در ادامه به بررسی الگوریتم ORB در جعل کپی-جابجایی استفاده شده پرداخته می‌شود.

در [۲۸]، الگوریتم ORB جهت شناسایی و توصیف ویژگی‌ها برای فرآیند تشخیص جعل کپی-جابجایی استفاده شده است. در [۲۹]، رویکرد جدیدی مبتنی بر الگوریتم ORB جهت جعل کپی-جابجایی استفاده شده است که از الگوریتم ORB جهت شناسایی و توصیف ویژگی‌ها و از  $K$  نزدیک‌ترین همسایه مبتنی بر فاصله همینگ جهت تطبیق استفاده شده است. در [۳۰]، از الگوریتم ORB جهت استخراج و توصیف ویژگی‌ها و از تطبیق گر Brute Force و فاصله همینگ جهت تطبیق به‌کار گرفته شده است. این روش در برابر تغییرات رنگی، شدت روشنایی نواحی جعل بسیار مناسب می‌باشد و از زمان اجرای کمتری برخوردار است. در [۳۱]، از الگوریتم ORB جهت شناسایی و توصیف ویژگی‌ها در جعل کپی-جابجایی به‌کار گرفته شده است که این رویکرد دقت بالاتر و زمان اجرای کمتری دارد. در [۳۲]، الگوریتم ORB جهت شناسایی و توصیف ویژگی‌ها، فاصله همینگ برای تطبیق و الگوریتم RANSAC جهت حذف تطبیق‌های نادرست به‌کار گرفته شده است. این روش در برابر تبدیل‌های هندسی نواحی جعل عملکرد موثرتری دارد.

<sup>5</sup> Features from Accelerated Segment Test

<sup>6</sup> Rosten

<sup>1</sup> Histogram Oriented Gradient

<sup>2</sup> Herbert Bay

<sup>3</sup> Hessian

<sup>4</sup> Nearest Neighbor





### • الگوریتم MIFT

الگوریتم MIFT نسخه توسعه یافته الگوریتم SIFT در مرحله توصیفگر می باشد که توسط گوا در سال ۲۰۰۹ ارائه شده است [۳۳]. این الگوریتم در مرحله استخراج ویژگی ها مشابه الگوریتم SIFT می باشد اما در مرحله توصیفگر نسبت به تبدیلات انعکاس آینه ثابت می باشند. این الگوریتم علاوه بر اینکه نسبت به تغییرات مقیاس و چرخش ثابت و مقاوم به تغییر زاویه است، نسبت به انعکاس آینه ثابت می باشند. در ادامه به بررسی الگوریتم MIFT و نسخه های بهبود یافته آن در جعل کپی-جابجایی پرداخته می شود.

در [۳۴]، الگوریتم MIFT بهبود یافته جهت شناسایی نقاط کلیدی در جعل کپی-جابجایی استفاده شده است که این روش در شناسایی نواحی چندگانه جعل دقت مناسبی دارد. در [۳۵]، روش جدیدی مبتنی بر الگوریتم MIFT برای شناسایی نواحی جعل کپی-جابجایی ارائه شده است. در این روش، ابتدا ویژگی ها توسط الگوریتم MIFT شناسایی می شود و سپس الگوریتم RANSAC جهت حذف تطبیق های نادرست استفاده شده است. در [۳۶]، الگوریتم MIFT برای شناسایی نواحی جعل کپی-جابجایی استفاده شده است. این روش نسبت به SIFT توانایی بیشتر در تشخیص جعل کپی-جابجایی دارد اما این روش در نواحی مسطح عملکرد مناسبی ندارد. در [۳۷]، تشخیص نواحی جعل کپی-جابجایی توسط الگوریتم MIFT ارائه شده است. در [۳۸]، جعل کپی-جابجایی تصویر توسط رویکرد جدیدی مبتنی بر MIFT پیشنهاد شده است. در این روش، ابتدا تصویر به بلوک های غیر هم پوشان تقسیم می شود و سپس ویژگی ها از هر بلوک توسط الگوریتم SIFT و MIFT استخراج می شود. این روش نسبت به نواحی جعل با تغییرات مقیاس، چرخش، نويز، تبدیلات انعکاس آینه ثابت می باشند.

### • الگوریتم KAZE

الگوریتم KAZE توسط آلکانتریللا در سال ۲۰۱۲ پیشنهاد شده است [۳۹]. ابتدا ویژگی ها توسط فضای مقیاس غیرخطی شناسایی می شوند و سپس برای هر ویژگی، یک جهت تعیین می شود. این ویژگی ها نسبت به تغییرات مقیاس و چرخش ثابت می باشند. در ادامه به بررسی الگوریتم KAZE در جعل کپی-جابجایی پرداخته می شود.

در [۴۰]، عملکرد الگوریتم SIFT، الگوریتم SURF و الگوریتم KAZE برای بررسی جعل کپی-جابجایی استفاده شده است. الگوریتم SURF نسبت به دو الگوریتم دیگر SIFT، KAZE سریعتر است اما الگوریتم SIFT نسبت به دو الگوریتم دیگر از دقت بهتری برخوردار است. الگوریتم KAZE دقت بهتری نسبت به SURF دارد اما سرعت بیشتری نسبت به SURF دارد. در [۴۱]، از الگوریتم KAZE جهت شناسایی نقاط کلیدی و از الگوریتم RANSAC جهت حذف تطبیق های نادرست در فرآیند تشخیص جعل کپی-جابجایی استفاده شده است. در [۴۲]، عملکرد الگوریتم های همچون SURF، KAZE، BRISK و هریس جهت شناسایی نقاط کلیدی در فرآیند تشخیص

جعل کپی-جابجایی به کار گرفته شده است که الگوریتم KAZE دقت و صحت بهتری نسبت به الگوریتم های دیگر دارد. در [۴۳]، الگوریتم KAZE و الگوریتم SIFT جهت شناسایی ویژگی ها برای شناسایی نواحی چندگانه جعل به کار گرفته شده است که این روش در برابر اعوجاج های مقیاس، چرخش و نويز عملکرد موثرتری دارد.

### • الگوریتم A-KAZE

الگوریتم A-KAZE نسخه توسعه یافته الگوریتم KAZE می باشد که توسط آلکانتریللا در سال ۲۰۱۳ معرفی شده است [۴۴]. این الگوریتم نسبت به الگوریتم KAZE سرعت بهتری دارد. ویژگی ها در روش A-KAZE توسط ماتریس هسیان شناسایی می شوند و سپس نقاطی که مقدار اکسترم آنها و مقدار اکسترم هسیان آنها از مقدار آستانه بیشتر باشد به عنوان نقاط کلیدی (ویژگی ها) در نظر گرفته می شوند. در ادامه به بررسی الگوریتم AKAZE در جعل کپی-جابجایی پرداخته می شود. در [۴۵]، شناساگر FAST، AKAZE جهت استخراج ویژگی ها و الگوریتم SIFT و DAISY جهت توصیف ویژگی ها جهت شناسایی نواحی جعل پیشنهاد شده است. این رویکرد نسبت به روش های دیگر با کاهش نرخ شناسایی اشتباه برخوردار است. در [۴۶]، شناسایی ویژگی ها توسط الگوریتم AKAZE، تطبیق توسط فاصله همینگ و g2NN برای شناسایی نواحی جعل چندگانه استفاده شده است. در [۴۷]، ویژگی ها توسط الگوریتم های AKAZE و SIFT استخراج و تطبیق توسط g2NN انجام شده است. این روش به طور موثر نواحی جعل چندگانه با تغییرات مقیاس، چرخش و نويز شناسایی می کند. در [۴۸]، الگوریتم های SURF بهبود یافته و AKAZE جهت شناسایی ویژگی ها در فرآیند جعل کپی-جابجایی پیشنهاد شده است.

### ۴-۱-۲- بررسی روش های تطبیق در تشخیص جعل کپی-

#### جابجایی مبتنی بر نقاط کلیدی

در این بخش به بررسی روش های رایج تطبیق همچون نزدیک ترین همسایه و کلاسترینگ پرداخته می شود.

#### • نزدیک ترین همسایه

تکنیک نزدیکترین همسایه شباهت بین فاصله نقاط ویژگی از هر نقطه کلیدی را نسبت به یکدیگر محاسبه می کند. سپس فاصله نقاط کلیدی که کمتر از آستانه از پیش تعیین شده باشند، تطبیق داده می شود. تکنیک های نزدیکترین همسایه برای رویکرد مبتنی بر نقطه کلیدی به چهار نوع، [۱۶] g2NN، 2NN، Best Bin First و روش های دیگر تقسیم می شوند که روش g2NN برای تشخیص جعل چندگانه کپی-جابجایی مناسب است [۳۰]. یکی از مشکلات این روش ها، ایجاد تعداد زیادی تطبیق های نادرست می باشد.

#### • کلاسترینگ

در تکنیک های کلاسترینگ (خوشه بندی)، اشیاء مشابه در یک دسته (خوشه) و اشیاء مختلف در یک دسته متفاوت قرار می گیرند. خوشه بندی سلسله مراتبی تجمعی، یک نمونه رایج تکنیک خوشه بندی



در تشخیص جعل کپی-جابجایی است. از مشکلات این روش، تطبیق‌های نادرست می‌باشد.

#### ۴-۲- تشخیص جعل کپی - جابجایی مبتنی بر بلوک

در روش‌های مبتنی بر بلوک، ابتدا تصویر به بلوک‌های مربعی یا دایره‌ای هم‌اندازه تقسیم می‌شود که ممکن است روی یکدیگر همپوشانی داشته باشند یا نداشته باشند [۵۲]. سپس ویژگی‌های هر بلوک شناسایی شده و بردار ویژگی به صورت یک ماتریس لغوی مرتب شده و جفت بلوک‌های مشابه تطبیق داده می‌شود تا مناطق کپی-جابجایی شناسایی شوند و در نهایت می‌توان از فیلترها و روش‌های مناسب جهت حذف تطبیق‌های نادرست برای بهبود دقت نواحی جعل استفاده کرد. در این روش‌ها به طور گسترده از الگوریتم‌های تبدیل کسینوسی گسسته، روش‌های مبتنی بر گشتاور ثابت، بافت شدت روشنایی و روش مبتنی بر تبدیل ویولت دوتایی جهت شناسایی ویژگی‌ها و از الگوریتم‌های همبستگی، فاصله اقلیدسی و مرتب‌سازی، جهت تطبیق استفاده می‌شود.

#### ۴-۲-۱- بررسی الگوریتم‌های استخراج ویژگی در روش -

##### های تشخیص جعل کپی-جابجایی مبتنی بر بلوک

در این بخش، برخی روش‌های رایج جهت شناسایی ویژگی هر بلوک شرح داده می‌شود. در ادامه به شرح هر یک از آنها پرداخته می‌شود.

##### • تبدیل کسینوسی گسسته

در بسیاری از روش‌های تشخیص جعل کپی-جابجایی مبتنی بر بلوک از تبدیل کسینوسی گسسته (DCT) استفاده شده است. DCT یک روش تبدیل ریاضی است که می‌تواند هر پیکسل از یک تصویر در دامنه فضایی را به ضرایب DCT در حوزه فرکانس تبدیل کند. اکثر اطلاعات سیگنال تمایل دارند در چند مؤلفه فرکانس پایین DCT متمرکز شوند. در [۴۹]، جعل کپی-جابجایی مبتنی بر تبدیل کسینوسی گسسته پیشنهاد شده است. ابتدا، تصاویر به بلوک‌های هم‌پوشان تقسیم می‌شود. سپس تبدیل کسینوس گسسته استفاده می‌شود و ضرایب تبدیل کسینوس گسسته به صورت زیگراگ مرتب می‌شوند و تطبیق مبتنی بر نزدیک‌ترین همسایه انجام می‌شود. این رویکرد در شناسایی نواحی جعل چندگانه موثر می‌باشد.

در [۵۰]، جعل کپی-جابجایی با استفاده از تبدیل کسینوسی گسسته ارائه شده است. در این رویکرد، ابتدا تصاویر به بلوک‌های هم‌پوشان با اندازه یکسان تقسیم می‌شود و تبدیل کسینوسی گسسته برای هر بلوک محاسبه می‌شود و سپس مرتب‌سازی لغوی برای ضرایب تبدیل کسینوسی گسسته انجام شود و در نهایت از نزدیک‌ترین همسایه جهت تطبیق استفاده می‌شود.

در [۵۱]، رویکرد مبتنی بر تبدیل کسینوسی گسسته برای جعل کپی-جابجایی ارائه شده است. در این روش، ابتدا تصاویر خاکستری به بلوک‌های با اندازه یکسان تقسیم می‌شود و سپس تبدیل کسینوسی گسسته برای هر بلوک به کار گرفته می‌شود و در نهایت Gaussian RBF kernel PCA برای ضرایب فرکانسی تبدیل کسینوسی گسسته استفاده می‌شود. این روش نسبت به تغییرات مقیاس، چرخش، محوشدگی، فشردگی، نویز و تبدیل غیرخطی مقاوم است.

در [۵۲]، جعل کپی-جابجایی توسط تبدیل کسینوسی گسسته و تبدیل ویولیت گسسته استفاده شده است. در این روش پس از بلوک‌بندی تصویر، تبدیل کسینوسی گسسته و تبدیل ویولیت گسسته به کار گرفته می‌شود. سپس همبستگی جهت تطبیق انجام می‌شود که تصویر باینری ایجاد می‌شود و نواحی سیاه نشان‌دهنده جعل می‌باشد که موقعیت نواحی جعل توسط شناساگر کنی بدست می‌آید. این روش از دقت مناسبی برخوردار است.

##### • روش مبتنی بر تبدیل ویولیت گسسته<sup>۲</sup>

در روش مبتنی بر تبدیل ویولیت گسسته، ابتدا تصویر با استفاده از تبدیل ویولیت گسسته تا مقیاس یک تجزیه شده و تنها از زیرباند HH1 و LL1 استفاده می‌شود. زیرباند LL1 یک برآورد از تصویر است که برای شناسایی نواحی تکراری بهتر می‌باشد که با اعمال فیلتر پایین‌گذر در جهت عمودی و افقی به دست می‌آید و به مؤلفه‌های فرکانس پایین ورودی اشاره دارد. همچنین زیرباند HH1 نویز موجود در تصویر را کدگذاری می‌کند که شامل اطلاعات فرکانس بالا است و پس از اعمال فیلتر بالاگذر در جهت عمودی و افقی به دست می‌آید.

در [۵۳]، تشخیص جعل کپی-جابجایی توسط تبدیل ویولیت گسسته و همبستگی فاز انجام شده است که این روش از نظر سرعت عملکرد موثری دارد. در [۵۴]، زیرباند LL1 از تبدیل ویولیت گسسته جهت تشخیص نواحی جعل از تصویر استفاده شده است که این روش سبب کاهش پیچیدگی محاسباتی و افزایش سرعت می‌شود. در [۵۵]، تبدیل ویولیت گسسته جهت تجزیه تصویر و شناسایی نواحی جعل پیشنهاد شده است. این روش نسبت به تبدیل فوری در آنالیز محتوای تصویر بسیار مناسب‌تر است. در [۵۶]، رویکرد جهت تشخیص جعل کپی-جابجایی پیشنهاد شده است. در این روش، ابتدا تصویر توسط تبدیل ویولیت گسسته تجزیه می‌شود و سپس تصویر به بلوک‌های هم‌پوشان تقسیم می‌شود و در نهایت با استفاده از مرتب‌سازی لغوی نواحی جعل کپی-جابجایی شناسایی می‌شود.

##### • روش مبتنی بر گشتاورهای ثابت Zernike

روش‌های مبتنی بر گشتاورهای ثابت Zernike به چرخش نواحی جعل کپی‌شده، ثلثت می‌باشد [۱]. در این روش، تصویر به بلوک‌های هم‌پوشان تقسیم می‌شود. اندازه گشتاور Zernike هر بلوک به عنوان بردار ویژگی در نظر گرفته می‌شود. این روش در برابر تغییرات مقیاس و تبدیل آفین نواحی جعل عملکرد موثری ندارد [۵۷، ۵۸].

<sup>1</sup>Discrete Cosine Transform

<sup>2</sup> Discrete Wavelet Transform



بنابراین تعیین روش مرتب‌سازی مناسب در سرعت الگوریتم و هزینه‌های محاسباتی آن تأثیر به‌سزایی دارد.

#### ۴-۳- تشخیص جعل کپی-جابجایی مبتنی بر یادگیری ماشین

یادگیری عمیق یکی از موضوعات روز است که کاربرد گسترده‌ای در زمینه‌های مختلف دارد. عملکرد روش‌های مبتنی بر یادگیری عمیق نسبت به روش‌های مبتنی بر نقاط کلیدی و مبتنی بر بلوک بهتر می‌باشد [۵۷]. در [۶۲]، روش dual branch CNN جهت تشخیص جعل کپی-جابجایی پیشنهاد شده است که این روش از دقت و سرعت بالایی برخوردار است. در [۶]، روش مبتنی بر شبکه عصبی پیچشی جهت تشخیص جعل کپی-جابجایی ارائه شده است که در این روش بر روی دیتابیس MICC-F220 به دقت ۱۰۰ درصد می‌رسد. در [۶۳]، روش جدید شبکه عصبی پیچشی مبتنی بر عمیق جهت تشخیص نواحی جعل ارائه شده است. در این روش از ۳۰ فیلتر بالاگذر به عنوان وزن‌های اولیه در شبکه عصبی پیشنهادی استفاده می‌شود. در [۶۴]، با استفاده از شبکه عصبی پیچشی عمیق<sup>۱</sup> و بخش‌بندی یک روش برای تشخیص نواحی جعل کپی-جابجایی پیشنهاد شده است. در [۶۵]، ویژگی‌ها توسط معماری ResNet جهت شناسایی نواحی جعل ارائه شده است.

#### ۵- پایگاه داده

تشخیص جعل کپی-جابجایی، یک شاخه جدید در پردازش تصویر می‌باشد. تعدادی پایگاه داده استاندارد برای ارزیابی روش‌ها ایجاد شده است که در ادامه به معرفی چند پایگاه داده رایج پرداخته می‌شود.

##### • مجموعه CASIA

مجموعه داده‌های CASIA محبوب‌ترین مجموعه جهت شناسایی جعل تصویر می‌باشد. دو نسخه از مجموعه داده‌های CASIA به نام CASIA v1 و CASIA v2 وجود دارد [۶۶]. نسخه اول این مجموعه شامل ۸۰۰ تصویر معتبر و ۹۲۱ تصویر جعلی می‌باشد. نسخه دوم مجموعه شامل ۷۲۰۰ تصویر معتبر و ۵۱۲۳ تصویر جعلی می‌باشد. هر دو مجموعه شامل تصاویر طبیعی، حیوانات و فضای داخلی می‌باشند که اندازه نواحی جعل با اندازه‌های مختلف از کوچک به بزرگ می‌باشد. نواحی جعل شامل اعوجاج‌های هندسی و رادیومتریکی می‌باشد که رزلوشن پایینی دارند.

##### • مجموعه Forensic

پایگاه داده Forensic در اولین چالش IEEE Forensics توسط کمیته فنی امنیت و اطلاعات قانونی در سال ۲۰۱۳ منتشر شد. این مجموعه داده شامل ۴۵۰ تصویر آموزشی و ۷۰۰ تصویر آزمایشی به اندازه ۲۰۱۸×۱۵ است.

در [۵۹]، روش گشتاور Zernike مبتنی بر تبدیل هارمونیک دایره‌ای و تبدیل فوریه ملین جهت استخراج ویژگی‌ها برای تشخیص نواحی جعل کپی-جابجایی ارائه شده است. در [۶۰]، روش گشتاور ثابت Zernike جهت تشخیص نواحی جعل کپی-جابجایی پیشنهاد شده است. این روش نسبت به چرخش و نویز مقاوم است. در [۶۱]، روش گشتاور ثابت fractional Zernike جهت تشخیص نواحی جعل کپی-جابجایی ارائه شده است.

#### ۴-۲-۲- بررسی روش‌های تطبیق در تشخیص جعل کپی-جابجایی مبتنی بر بلوک

در این بخش، به بررسی روش‌های رایج تطبیق در تشخیص جعل کپی-جابجایی مبتنی بر بلوک همچون همبستگی، فاصله اقلیدسی و مرتب‌سازی پرداخته می‌شود. در ادامه به شرح جزئیات آنها پرداخته می‌شود.

##### • همبستگی

در این روش میزان تشابه بین بلوک‌ها محاسبه شده و حداکثر شباهت‌ها به عنوان موارد مشابه در نظر گرفته می‌شود. معمولاً از ضرایب همبستگی برای تعیین نواحی جعلی پس از مرتب‌سازی استفاده می‌شود. هرچند که ضرایب همبستگی را می‌توان به طور مستقل و بدون مرتب‌سازی در روش‌های تطبیق مبتنی بر بلوک استفاده کرد. در این روش ممکن است نواحی با تشابه میزان شدت روشنایی، به اشتباه تطبیق داده شود که سبب تطبیق‌های نادرست و در نهایت تشخیص نادرست نواحی جعل می‌گردد.

##### • فاصله اقلیدسی

این روش، فواصل بین بلوک‌ها را اندازه می‌گیرد و بلوک‌های مشابه را تطبیق می‌دهد. فاصله اقلیدسی، مشابه روش همبستگی، برای تعیین مناطق دستکاری (جعل) شده پس از فرآیند مرتب‌سازی استفاده می‌شود. یکی از مشکلات این روش، ایجاد تطبیق‌های چندگانه می‌باشد.

##### • مرتب‌سازی

یکی از روش‌های رایج و مهم تطبیق جهت تشخیص جعل کپی-جابجایی، عمل مرتب‌سازی بردار ویژگی جفت بلوک‌های مشابه می‌باشد. هدف از مرتب‌سازی داده، چیدمان داده‌ها در قالبی خاص است. الگوریتم مرتب‌سازی روشی برای چیدمان داده‌ها با ترتیبی خاص تعیین می‌کند. اغلب ترتیب‌های رایج به صورت ترتیب عددی یا الفبایی هستند. اهمیت مرتب‌سازی در این نکته است که جستجوی داده‌ها در صورت مرتب بودن می‌تواند تا سطح بالایی بهینه‌سازی شود. در فرآیند تشخیص جعل کپی-جابجایی، معمولاً پس از مرتب‌سازی، عمل جستجو در ماتریس ویژگی انجام می‌شود تا بردارهای مشابه در مجاورت هم قرار گیرند و تطبیق سریع‌تر و ساده‌تر صورت گیرد.

<sup>1</sup> deep convolutional neural network



#### • مجموعه CoMoFoD

می‌شود، عملکرد تشخیص بایستی در دو سطح تحلیل شود. در ادامه به معرفی چند تا از این معیارهای ارزیابی رایج پرداخته می‌شود.

مجموعه CoMoFoD شامل تصاویر جعل کپی-جابجایی می‌باشد. این پایگاه داده شامل ۲۰۰ تصویر کوچک با اندازه  $512 \times 512$  و ۶۰ تصویر بزرگ با اندازه  $3000 \times 2000$  می‌باشد و مقدار نواحی جعل از ۰/۱۱ تا ۱۷/۳۴ درصد تصاویر است [۶۷]. این مجموعه برای ایجاد تصویر جعل کپی-جابجایی از اعوجاج‌های همچون انتقال، چرخش، تغییرات مقیاس، فشرده‌سازی JPEG، محوشدگی، اضافه کردن نویز و کاهش رنگ استفاده می‌کند.

#### ۶-۱- معیارهای ارزیابی در سطح پایگاه داده

هدف از معیارهای ارزیابی در سطح پایگاه داده اینست که چه تعداد از تصاویر جعلی یا معتبر تشخیص داده می‌شود. در این معیارها، تعداد تصاویر پایگاه داده ارزیابی می‌شود. در ادامه به شرح چند معیار ارزیابی رایج در سطح پایگاه داده بررسی می‌شود.

#### • مجموعه GRIP

مجموعه CRIP شامل ۸۰ تصویر کپی-جابجایی و ۸۰ تصویر معتبر است [۶۸]. تمام تصاویر این پایگاه داده فقط دارای یک منطقه نواحی جعل می‌باشد. تصاویر جعل فقط شامل حرکت انتقالی می‌باشد و تغییرات مقیاس و چرخش ندارد.

#### • دقت تشخیص

دقت تشخیص مطابق فرمول (۱) محاسبه می‌شود.

$$\text{precision} = \frac{T_p}{T_p + F_p} \quad (1)$$

در این رابطه،  $T_p$  تعداد تصاویر جعل شده که به درستی به عنوان تصویر جعل شناسایی شده است و  $F_p$  تعداد تصاویر معتبر که به اشتباه به عنوان تصویر جعل شناسایی شده است.

#### • مجموعه COVERAGE

مجموعه COVERAGE، یک مجموعه جعل کپی-جابجایی با اشیاء واقعی می‌باشند [۶۹]. شش نوع عملیات همچون انتقال، تغییر مقیاس، تغییر چرخش، تبدیل فرم، تغییرات روشنایی و ادغام برای ایجاد تصاویر جعل کپی-جابجایی استفاده شده است.

#### • فراخوانی

فراخوانی مطابق فرمول (۲) محاسبه می‌شود.

$$\text{Recall} = \frac{T_p}{T_p + F_N} \quad (2)$$

در این رابطه،  $T_p$  تعداد تصاویر جعل شده که به درستی به عنوان تصویر جعل شناسایی شده است و  $F_N$  تعداد تصاویر جعل شده که به اشتباه به عنوان تصویر معتبر شناخته شده است.

#### • مجموعه MICC-F600

مجموعه MICC-F600 شامل ۴۴۰ تصویر معتبر و ۱۶۰ تصویر جعل کپی-جابجایی می‌باشد [۱۳]. تصاویر جعل کپی-جابجایی در این مجموعه بسیار مبتدی می‌باشد که دستکاری را می‌توان به راحتی توسط چشم انسان تشخیص داد.

#### • F1

معیار F1 مطابق فرمول (۳) محاسبه می‌شود.

$$F1 = 2 \frac{\text{precision} \times \text{Recall}}{\text{precision} + \text{Recall}} \quad (3)$$

#### • مجموعه FAU

مجموعه FAU شامل ۴۸ تصویر معتبر می‌باشد و از هر تصویر معتبر، یک تصویر جعل کپی-جابجایی ایجاد شده است [۷۰]. اعوجاج‌های همچون فشرده‌سازی JPEG، نویز، تغییرات مقیاس و چرخش برای ایجاد دستکاری تصاویر استفاده شده است. دستکاری تصاویر در این مجموعه بسیار ماهرانه انجام شده است که تصاویر جعل هم مشابه تصاویر معتبر می‌باشد.

#### ۶-۲- معیارهای ارزیابی در سطح پیکسل

هدف از معیارهای ارزیابی در سطح پیکسل اینست که چه تعداد از پیکسل‌ها به صورت صحیح جعلی یا معتبر تشخیص داده می‌شود. در این معیارها، یک تصویر به تنهایی ارزیابی می‌شود. در ادامه به شرح چند معیار ارزیابی رایج در سطح پیکسل پرداخته می‌شود.

#### • مجموعه MICC-F220

مجموعه MICC-F220 شامل ۱۱۰ تصویر معتبر و ۱۱۰ تصویر جعلی می‌باشد [۱۳]. این مجموعه شامل تصاویر طبیعی می‌باشد. وضوح تصاویر از  $722 \times 480$  به  $800 \times 600$  پیکسل‌ها متغییر است و اندازه پچ جعلی به طور متوسط ۱/۲ درصد کل تصویر را پوشش داده است.

#### • دقت

دقت مطابق فرمول (۴) محاسبه می‌شود.

$$\text{precision} = \frac{T_p}{T_p + F_p} \quad (4)$$

در این رابطه،  $T_p$  تعداد پیکسل‌های جعل شده که به درستی به عنوان پیکسل جعل شناسایی شده است و  $F_p$  تعداد پیکسل‌های معتبر که به اشتباه به عنوان پیکسل جعل شناسایی شده است.

#### • فراخوانی

معیار فراخوانی مطابق فرمول (۵) محاسبه می‌شود.

#### ۶- معیارهای ارزیابی


مهم‌ترین فاکتور در ارزیابی روش‌های تشخیص جعل، توانایی آن‌ها در شناسایی تصویر معتبر از جعلی می‌باشد. با این حال، قدرت و دقت یک الگوریتم به درست تشخیص دادن ناحیه جعل نیز بسیار قابل توجه است، به ویژه هنگامی که تشخیص چشمی جعل امکان‌پذیر نباشد. بنابراین، وقتی یک الگوریتم تشخیص جعل کپی-جابجایی ارزیابی



که نشان دهنده بیشترین چالش در این زمینه می باشد. چالش های موجود در روش های مبتنی بر بلوک نسبت به تبدیل های هندسی مقاوم نمی باشند که اخیراً با ترکیب با روش های مبتنی بر نقاط کلیدی یا بهبود جزئی هر یک از روش های مبتنی بر بلوک توانستند در این زمینه عملکرد خوبی داشته باشند و به همین دلیل امروزه بهبود این روش ها بیشترین تعداد مقالات دارند. از طرف دیگر، روش های مبتنی بر یادگیری عمیق به طور گسترده در زمینه های دیگر پردازش تصویر کاربرد گسترده ای دارد اما این روش ها معمولاً به اندازه تصویر ثابت و تعداد زیادی داده های آموزشی و آزمایشی در تشخیص جعل کپی-جابجایی نیاز دارند. بنابراین، نتایج تشخیص روش های مبتنی بر یادگیری عمیق کاملاً به کیفیت داده های آموزشی بستگی دارد. به طور خلاصه، روش های موجود مبتنی بر یادگیری عمیق هنوز هم برای تشخیص جعل کپی-جابجایی خوب عمل نمی کنند. روش های مبتنی بر نقاط کلیدی با توجه به اینکه الگوریتم های بسیاری نسبت به تبدیل های هندسی ثابت می باشند، اخیراً چالش جهت بهبود این الگوریتم ها در زمینه جعل کپی-جابجایی بسیار کم می باشد و به همین دلیل اخیراً تعداد مقالات در بهبود این زمینه کم می باشد.

## ۸- جمع بندی

تصاویر دیجیتال به طور گسترده در زمینه های مختلف همچون پزشکی، صنعت روزنامه، جنایی، سنجش از دور و غیره کاربرد دارند. بنابراین موثق بودن این تصاویر بسیار مهم می باشد. امروزه روش های گوناگونی جهت جعل تصاویر دیجیتال وجود دارد که جعل کپی-جابجایی تصویر یکی از رایج ترین و ساده ترین جعل ها می باشد که تشخیص اینگونه جعل مورد توجه محققان متعددی قرار گرفته است. در این مقاله، ضمن معرفی مفاهیم جعل کپی-جابجایی تصویر، به بررسی مراحل، دسته بندی روش های تشخیص و سوگیری تحقیقات در این زمینه ارائه شد. از ویژگی های دیگر این مقاله، مشخص کردن رویکردهای تحقیقات آینده در این زمینه است. مقالات این حوزه نشان می دهد، هنوز



شکل (۲): نمودار تعداد مقالات بر حسب روش های مختلف جعل کپی-جابجایی

در این رابطه،  $TP$  تعداد پیکسل های جعل شده که به درستی به عنوان پیکسل جعل شناسایی شده است و  $FN$  تعداد پیکسل جعل شده که به اشتباه به عنوان پیکسل معتبر شناخته شده است.

### • میانگین هارمونیک

میانگین هارمونیک ترکیب دقت و فراخوانی می باشد که مطابق فرمول (۶) محاسبه می شود.

$$F1 = 2 \frac{\text{precision} \times \text{Recall}}{\text{precision} + \text{Recall}} \quad (6)$$

### • نرخ دقت تشخیص در سطح پیکسل

نرخ دقت تشخیص در سطح پیکسل معیاری است که برای تعیین دقت و مقاوم بودن عملکرد الگوریتم در سطح پیکسل ارائه شده است. این معیار مطابق فرمول (۷) محاسبه می شود.

$$DAR = \frac{|\varphi_S \cap \bar{\varphi}_S| + |\varphi_T \cap \bar{\varphi}_T|}{|\varphi_S| + |\varphi_T|} \quad (7)$$

$\varphi_S$  نواحی کپی،  $\bar{\varphi}_S$  نواحی کپی شناسایی شده، همچنین  $\varphi_T$  و  $\bar{\varphi}_T$  به ترتیب نواحی جعل شده و نواحی جعل تشخیص داده شده، هستند.

### • نرخ تشخیص اشتباه در سطح پیکسل

نرخ تشخیص اشتباه در سطح پیکسل نشان می دهد که در یک الگوریتم تشخیص جعل چند درصد از پیکسل هایی که جعلی نیستند، به اشتباه جعلی تشخیص داده می شود. نرخ تشخیص اشتباه در سطح پیکسل مطابق رابطه (۸) محاسبه می شود.

$$FPR = \frac{|\bar{\varphi}_S - \varphi_S| + |\bar{\varphi}_T - \varphi_T|}{|\bar{\varphi}_S| + |\bar{\varphi}_T|} \quad (8)$$

در این رابطه،  $|\bar{\varphi}_S - \varphi_S|$  تفاضل نواحی از پیکسل ها را مشخص می کند که کپی شده و کپی نیز تشخیص داده شده،  $|\bar{\varphi}_T - \varphi_T|$  تفاضل نواحی از پیکسل ها را مشخص می کند که جعلی می باشد و جعلی نیز تشخیص داده شده است.

## ۷- رویکردهای جدید

با توجه به تحقیق های زیادی که جهت تشخیص جعل کپی-جابجایی انجام شده است اما هنوز به دلیل متنوع بودن نوع تبدیل های هندسی، رادپومتریک و آفین جهت کپی نواحی جعل، یک روش عمومی و کامل جهت تشخیص جعل وجود ندارد. پس برای تشخیص نواحی جعل کپی-جابجایی باید به نوع تبدیل ها جهت کپی نواحی جعل و تعداد نواحی جعل هم توجه کرد. بر این اساس بررسی هایی بین روش های مبتنی بر نقاط کلیدی، روش های مبتنی بر بلوک و روش های مبتنی بر یادگیری عمیق در محدوده های سال های (۲۰۱۵-۲۰۲۳) در پایگاه IEEE مورد بررسی قرار گرفته است (شکل (۲)). با توجه به این بررسی می توان نتیجه گرفت که اخیراً روش های مبتنی بر نقاط کلیدی کمتر از روش های دیگر کاربرد دارد که این نشان می دهد که در این روش چالش کمتری وجود دارد. روش های مبتنی بر یادگیری عمیق بیشتر از روش های مبتنی بر نقاط کلیدی کاربرد دارد اما روش های مبتنی بر بلوک بیشترین کاربرد در تشخیص نواحی جعل کپی-جابجایی دارد



چالش‌هایی در روش‌های مبتنی بر بلوک و روش‌های مبتنی بر یادگیری عمیق وجود دارد که بهبود این روش‌ها در ارتقا دقت تشخیص جعل کپی-جابجایی بسیار حائز اهمیت است.

## مراجع

- in *Proceedings of Digital Forensic Research Workshop*, 2003.
- [16] Z. H.-N. a. M. Nasri, "Copy-Move Image Forgery Detection Using Redundant Keypoint Elimination Method," in *Cryptographic and Information Security Approaches for Images and Videos*, S. Ramakrishnan, Ed. Boca Raton: CRC Press, pp. 773-797, 2019.
- [17] C.-C. Chen, W.-Y. Lu, and C.-H. Chou, "Rotational copy-move forgery detection using SIFT and region growing strategies," *Multimedia Tools and Applications*, pp. 1-16, 2019.
- [18] J. Li, X. Li, B. Yang, and X. Sun, "Segmentation-based image copy-move forgery detection scheme," *IEEE Transactions on Information Forensics and Security*, vol. 10, pp. 507-518, 2014.
- [19] S. Prasad and B. Ramkumar, "Passive copy-move forgery detection using SIFT, HOG and SURF features," in *2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, 2016, pp. 706-710.
- [20] H. Bay, T. Tuytelaars, and L. Van Gool, "Surf: Speeded up robust features," in *Computer vision—ECCV 2006*, ed: Springer, 2006, pp. 404-417.
- [21] M. F. Hashmi, V. Anand, and A. G. Keskar, "A copy-move image forgery detection based on speeded up robust feature transform and Wavelet Transforms," in *2014 international conference on computer and communication technology (ICCT)*, 2014, pp. 147-152.
- [22] C. Wang, Z. Zhang, Q. Li, and X. Zhou, "An image copy-move forgery detection method based on SURF and PCET," *IEEE Access*, vol. 7, pp. 170032-170047, 2019.
- [23] M. Bilal, H. A. Habib, Z. Mehmood, T. Saba, and M. Rashid, "Single and multiple copy-move forgery detection and localization in digital images based on the sparsely encoded distinctive features and DBSCAN clustering," *Arabian Journal for Science and Engineering*, vol. 45, pp. 2975-2992, 2020.
- [24] A. Badr, A. Youssif, and M. Wafi, "A robust copy-move forgery detection in digital image forensics using SURF," in *2020 8th International Symposium on Digital Forensics and Security (ISDFS)*, 2020, pp. 1-6.
- [25] R. Rakhi, A. J. Sundararaj, R. C. Joy, and J. J. Winston, "Effective Detection of Copy Move Forgery Using Surf," in *2023 4th International Conference on Signal Processing and Communication (ICSPC)*, 2023, pp. 306-310.
- [26] E. Rosten, R. Porter, and T. Drummond, "Faster and better: A machine learning approach to corner detection," *IEEE transactions on pattern analysis and machine intelligence*, vol. 32, pp. 105-119, 2008.
- [27] B. Fatima, A. Ghafoor, S. S. Ali, and M. M. Riaz, "FAST, BRIEF and SIFT based image copy-move forgery detection technique," *Multimedia Tools and Applications*, vol. 81, pp. 43805-43819, 2022.
- [28] G. Muzaffer, O. Makul, B. Ustubioglu, and G. Ulutas, "Copy move forgery detection using gabor filter and orb," in *Proc. 2016International Conf. Image Process. Prod. Comput. Sci.*, 2016, pp. 23-29.
- [29] V. Mehta, A. K. Jaiswal, and R. Srivastava, "Copy-move image forgery detection using DCT and ORB feature set," in *Futuristic Trends in Networks and Computing Technologies: Second International Conference, FTNCT 2019, Chandigarh, India*,
- [1] B. Soni, P. K. Das, and D. M. Thounaojam, "CMFD: a detailed review of block based and key feature based techniques in image copy-move forgery detection," *IET Image Processing*, vol. 12, pp. 167-178, 2018.
- [2] A. Dixit and R. Gupta, "Copy-Move Image Forgery Detection a Review," *International Journal of Image, Graphics and Signal Processing*, vol. 8, p. 29, 2016.
- [3] M. A. Qureshi and M. Deriche, "A review on copy move image forgery detection techniques," in *2014 IEEE 11th International Multi-Conference on Systems, Signals & Devices (SSD14)*, 2014, pp. 1-5.
- [4] N. T. Pham and C.-S. Park, "Toward Deep-Learning-Based Methods in Image Forgery Detection: A Survey," *IEEE Access*, vol. 11, pp. 11224-11237, 2023.
- [5] A. Bensaad, K. Loukhaoukha, and S. Sadoudi, "Keypoint-based copy-move forgery detection in digital images: a survey," in *2022 7th International Conference on Image and Signal Processing and their Applications (ISPA)*, 2022, pp. 1-6.
- [6] K. M. Hosny, A. M. Mortda, M. M. Fouda, and N. A. Lashin, "An efficient CNN model to detect copy-move image forgery," *IEEE Access*, vol. 10, pp. 48622-48632, 2022.
- [7] D. Chauhan, D. Kasat, S. Jain, and V. Thakare, "Survey on keypoint based copy-move forgery detection methods on image," *Procedia Computer Science*, vol. 85, pp. 206-212, 2016.
- [8] B. Ustubioglu, G. Tahaoglu, and G. Ulutas, "Detection of audio copy-move-forgery with novel feature matching on Mel spectrogram," *Expert Systems with Applications*, vol. 213, p. 118963, 2023.
- [9] N. Kumar and T. Meenpal, "Salient keypoint-based copy-move image forgery detection," *Australian Journal of Forensic Sciences*, vol. 55, pp. 331-354, 2023.
- [10] D. G. Lowe, "Distinctive image features from scale-invariant keypoints," *International journal of computer vision*, vol. 60, pp. 91-110, 2004.
- [11] Y. Fan, Y.-S. Zhu, and Z. Liu, "An improved SIFT-based copy-move forgery detection method using T-linkage and multi-scale analysis," *Journal of Information Hiding and Multimedia Signal Processing*, vol. 7, pp. 399-408, 2016.
- [12] R. C. Pandey, S. K. Singh, K. Shukla, and R. Agrawal, "Fast and robust passive copy-move forgery detection using SURF and SIFT image features," in *2014 9th International conference on industrial and information systems (ICIIS)*, 2014, pp. 1-6.
- [13] I. Amerini, L. Ballan, R. Caldelli, A. Del Bimbo, and G. Serra, "A sift-based forensic method for copy-move attack detection and transformation recovery," *IEEE transactions on information forensics and security*, vol. 6, pp. 1099-1110, 2011.
- [14] A. C. Popescu and H. Farid, "Exposing digital forgeries by detecting duplicated image regions," *Dept. Comput. Sci., Dartmouth College, Tech. Rep. TR2004-515*, pp. 1-11, 2004.
- [15] A. J. Fridrich, B. D. Soukal, and A. J. Lukáš, "Detection of copy-move forgery in digital images," in



- [45] A. Dixit and S. Bag, "Composite attacks-based copy-move image forgery detection using AKAZE and FAST with automatic contrast thresholding," *IET Image Processing*, vol. 14, pp. 4528-4542, 2020.
- [46] X. Zhou and Q. Shi, "Multiple copy-move forgery detection based on density clustering," *Pattern Recognition and Image Analysis*, vol. 31, pp. 109-116, 2021.
- [47] C. S. Prakash, P. P. Panzade, H. Om, and S. Maheshkar, "Detection of copy-move forgery using AKAZE and SIFT keypoint extraction," *Multimedia Tools and Applications*, vol. 78, pp. 23535-23558, 2019.
- [48] S. K. Narasimhamurthy, V. K. Mahadevachar, and R. K. T. Narasimhamurthy, "A Copy-Move Image Forgery Detection Using Modified SURF Features and AKAZE Detector," *International Journal of Intelligent Engineering & Systems*, vol. 16, 2023.
- [49] S. Kumar, J. Desai, and S. Mukherjee, "A fast DCT based method for copy move forgery detection," in *2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013)*, 2013, pp. 649-654.
- [50] E. A. Armas Vega, E. González Fernández, A. L. Sandoval Orozco, and L. J. García Villalba, "Copy-move forgery detection technique based on discrete cosine transform blocks features," *Neural Computing and Applications*, vol. 33, pp. 4713-4727, 2021.
- [51] M. A. S. Kumar, "IMAGE FORENSIC FOR DIGITAL IMAGE COPY MOVE FORGERY DETECTION," *IMAGE*, vol. 52, 2023.
- [52] A. Shankar, P. Swetha, and B. Ramu, "Image Forgery Detection Method for Copy-Move and Splicing Attacks Using DCT, DWT And Correlation," *Journal of Pharmaceutical Negative Results*, pp. 3878-3883, 2022.
- [53] S. Khan and A. Kulkarni, "Reduced time complexity for detection of copy-move forgery using discrete wavelet transform," *International Journal of Computer Applications*, vol. 6, pp. 31-36, 2010.
- [54] S. Mushtaq, R. A. Khan, S. A. Lone, A. Moon, and M. Qadri, "Improved Complexity in Localization of Copy-Move Forgery Using DWT," in *International Conference on Computing, Communications, and Cyber-Security*, 2022, pp. 825-839.
- [55] R. Ashraf, M. S. Mehmood, T. Mahmood, J. Rashid, M. W. Nisar, and M. Shah, "An efficient forensic approach for copy-move forgery detection via discrete wavelet transform," in *2020 International Conference on Cyber Warfare and Security (ICWS)*, 2020, pp. 1-6.
- [56] P. Yadav and Y. Rathore, "Detection of copy-move forgery of images using discrete wavelet transform," *International Journal on Computer Science and Engineering*, vol. 4, p. 565, 2012.
- [57] S.-J. Ryu, M.-J. Lee, and H.-K. Lee, "Detection of copy-rotate-move forgery using Zernike moments," in *International workshop on information hiding*, 2010, pp. 51-65.
- [58] B. Patel and S. Degadwala, "A Survey Paper on Image forgery detection Using Pseudo Zernike Moment," 2020.
- [59] S. Velmurugan and T. Subashini, "Patch-match based detection of copy-move forgeries using rotation invariant features," *Materials Today: Proceedings*, vol. 33, pp. 4686-4690, 2020.
- [30] Z. Xue, L. Tian, and C. Li, "Passive Image Copy-Move Forgery Detection Based on ORB Features," in *Recent Developments in Intelligent Computing, Communication and Devices: Proceedings of ICCD 2019 5*, 2021, pp. 312-317.
- [31] K.-T. Huynh, T.-N. Ly, and T. Le-Tien, "ORB for Detecting Copy-Move Regions with Scale and Rotation in Image Forensics," in *Future Data and Security Engineering. Big Data, Security and Privacy, Smart City and Industry 4.0 Applications: 7th International Conference, FDSE 2020, Quy Nhon, Vietnam, November 25-27, 2020, Proceedings 7*, 2020, pp. 358-372.
- [32] Y. Zhu, X. Shen, and H. Chen, "Copy-move forgery detection based on scaled ORB," *Multimedia Tools and Applications*, vol. 75, pp. 3221-3233, 2016.
- [33] X. Guo, X. Cao, J. Zhang, and X. Li, "Mift: A mirror reflection invariant feature descriptor," in *Asian Conference on Computer Vision*, 2009, pp. 536-545.
- [34] M. Jaber, G. Bebis, M. Hussain, and G. Muhammad, "Accurate and robust localization of duplicated region in copy-move image forgery," *Machine vision and applications*, vol. 25, pp. 451-475, 2014.
- [35] M. Jaber, G. Bebis, M. Hussain, and G. Muhammad, "Improving the detection and localization of duplicated regions in copy-move image forgery," in *2013 18th international conference on digital signal processing (DSP)*, 2013, pp. 1-6.
- [36] V. Agarwal and V. Mane, "Reflective SIFT for improving the detection of copy-move image forgery," in *2016 Second International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*, 2016, pp. 84-88.
- [37] V. Dhanial and H. B. KP, "Improving Digital Image Forgery Detection Using MIFT Features and Adaptive Over Segmentation," 2016.
- [38] A. J. Mariyal, "AN EFFICIENT IMAGE FORGERY DETECTION USING SIFT AND MIFT."
- [39] P. F. Alcantarilla, A. Bartoli, and A. J. Davison, "KAZE features," in *European conference on computer vision*, 2012, pp. 214-227.
- [40] A. Rani and A. Jain, "Copy-Move Image Forgery Detection Using SURF, SIFT, and KAZE," in *Proceedings of 3rd International Conference on Machine Learning, Advances in Computing, Renewable Energy and Communication: MARC 2021*, 2022, pp. 719-726.
- [41] D. Vaishnavi, G. Balaji, and D. Mahalakshmi, "KAZE feature based passive image forgery detection," in *First International Conference on Artificial Intelligence and Cognitive Computing: AICC 2018*, 2019, pp. 333-340.
- [42] A. Kaur, S. Walia, and K. Kumar, "Comparative analysis of different keypoint based copy-move forgery detection methods," in *2018 Eleventh International Conference on Contemporary Computing (IC3)*, 2018, pp. 1-5.
- [43] F. Yang, J. Li, W. Lu, and J. Weng, "Copy-move forgery detection based on hybrid features," *Engineering Applications of Artificial Intelligence*, vol. 59, pp. 73-83, 2017.
- [44] P. Alcantarilla, J. Nuevo, and A. Bartoli, "Fast explicit diffusion for accelerated features in nonlinear scale spaces british machine vision conference (BMVC)," ed: Bristol, 2013.



- [60] K. A. Tatkare and M. Devare, "Novel Method to Detect Multiple Cloning in Targeted Image Invariant to Rotation," in *Computing in Engineering and Technology: Proceedings of ICCET 2019*, 2020, pp. 65-74.
- [61] B. Chen, M. Yu, Q. Su, H. J. Shim, and Y.-Q. Shi, "Fractional quaternion Zernike moments for robust color image copy-move forgery detection," *IEEE Access*, vol. 6, pp. 56637-56646, 2018.
- [62] N. Goel, S. Kaur, and R. Bala, "Dual branch convolutional neural network for copy move forgery detection," *IET Image Processing*, vol. 15, pp. 656-665, 2021.
- [63] Y. Rao and J. Ni, "A deep learning approach to detection of splicing and copy-move forgeries in images," in *2016 IEEE international workshop on information forensics and security (WIFS)*, 2016, pp. 1-6.
- [64] Abhishek and N. Jindal, "Copy move and splicing forgery detection using deep convolution neural network, and semantic segmentation," *Multimedia Tools and Applications*, vol. 80, pp. 3571-3599, 2021.
- [65] B. Ahmed, T. A. Gulliver, and S. alZahir, "Image splicing detection using mask-RCNN," *Signal, Image and Video Processing*, vol. 14, pp. 1035-1042, 2020.
- [66] J. Dong, W. Wang, and T. Tan, "Casia image tampering detection evaluation database," in *2013 IEEE China summit and international conference on signal and information processing*, 2013, pp. 422-426.
- [67] D. Tralic, I. Zupancic, S. Grgic, and M. Grgic, "CoMoFoD—New database for copy-move forgery detection," in *Proceedings ELMAR-2013*, 2013, pp. 49-54.
- [68] D. Cozzolino, G. Poggi, and L. Verdoliva, "Efficient dense-field copy-move forgery detection," *IEEE Transactions on Information Forensics and Security*, vol. 10, pp. 2284-2297, 2015.
- [69] B. Wen, Y. Zhu, R. Subramanian, T.-T. Ng, X. Shen, and S. Winkler, "COVERAGE—A novel database for copy-move forgery detection," in *2016 IEEE international conference on image processing (ICIP)*, 2016, pp. 161-165.
- [70] V. Christlein, C. Riess, J. Jordan, C. Riess, and E. Angelopoulou, "An evaluation of popular copy-move forgery detection approaches," *IEEE Transactions on information forensics and security*, vol. 7, pp. 1841-1854, 2012.





## مدل سلامت سیستم قدرت با حضور نیروگاه فتوولتائیک

ایوب علی‌پور<sup>۱</sup>، امیر قاندری<sup>۲\*</sup>، حمید کیوانی<sup>۱</sup>

۱- گروه مهندسی برق، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

۲- گروه مهندسی برق، واحد داریون، دانشگاه آزاد اسلامی، داریون، ایران

Amir.ghaedi@iau.ac.ir

**چکیده:** نیروگاه‌های فتوولتائیک انرژی تابشی خورشید را به برق تبدیل می‌کند. به دلیل تغییر تابش خورشید، توان تولیدی این نیروگاه‌ها تغییر می‌کند که بر موضوعات مختلف از جمله بهره‌برداری سیستم قدرت تاثیر می‌گذارد. در بهره‌برداری سیستم قدرت، به منظور حفظ تعادل تولید و مصرف و ثابت نگه داشتن فرکانس مقاداری رزرو در نظر گرفته می‌شود. برخلاف مطالعات قبل که رزرو را به صورت درصدی از بار، تولید یا بر اساس ریسک محاسبه می‌کردند، در مدل سلامت سیستم قدرت، هم از مدل احتمالاتی نیروگاه‌های موجود و هم از قواعد تجربی جهت تعیین شاخص‌ها استفاده می‌شود. این مدل، هم مبتنی بر ریسک بوده و هم میزان رزرو از ظرفیت بزرگترین واحد تولید بیشتر می‌باشد. در این مقاله مدل سلامت سیستم قدرت با حضور نیروگاه فتوولتائیک به دست آورده می‌شود. برای این منظور مدل قابلیت اطمینان نیروگاه فتوولتائیک با در نظر گرفتن خرابی اجزای تشکیل‌دهنده و تغییرات تابش خورشید به دست آورده می‌شود. نتایج شبیه‌سازی نیز به منظور بررسی تاثیر نیروگاه‌های فتوولتائیک بر شاخص‌های مدل سلامت شامل احتمال حالت‌های سلامت، حاشیه و ریسک ارائه می‌شود. این نتایج نشان می‌دهد نیروگاه‌های فتوولتائیک سبب بهبود شاخص‌های بهره‌برداری سیستم قدرت می‌شوند اما تاثیر آن‌ها به دلیل تغییرات تابش خورشید کمتر از نیروگاه‌های متداول است.

**واژه‌های کلیدی:** انرژی‌های تجدیدپذیر، بهره‌برداری شبکه قدرت، رزرو چرخان، مدل سلامت، نیروگاه فتوولتائیک

## Well-Being Model of Power System with Photovoltaic Unit

Ayub Alipour<sup>1</sup>, Amir Ghaedi<sup>2\*</sup>, Hamid Keyvani<sup>1</sup>

<sup>1</sup> Department of Electrical Engineering, Kazeroun Branch, Islamic Azad University, Kazeroun, Iran

<sup>2</sup> Department of Electrical Engineering, Daiun Branch, Islamic Azad University, Dariun, Iran

[amir.ghaedi@iau.ac.ir](mailto:amir.ghaedi@iau.ac.ir)

### Abstract:

PV units convert solar energy into electricity. Since, the solar radiation is variable, the production power changes that affects various topics such as power system operation. In the operation of the power system, to maintain the balance of production and consumption, some reserve is considered. Unlike past studies that reserve is considered as percentage of power or load, or based on risk criteria, in well-being model of power system, both probabilistic model and empirical rules are used to determine the indices. This model is based on risk and the amount of reserve is higher than the capacity of the largest unit. In this paper, the well-being model of the power system with the presence of PV plants is obtained. For this purpose, the reliability model of PV plant is obtained by considering components failure and changes in solar radiation. The simulation results are also presented to investigate the impact of PV plants on well-being model indices. Numerical results show the PV units improve reliability-based operation indices of power system. However, due to the variation in solar radiation, the impact of PV units on reliability indices is less than conventional units.

**Keywords:** renewable energies, power system operation, spinning reserve, well-being model, photovoltaic power plant.

DOI: 00.00000/0000

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۲/۰۳/۲۷

تاریخ پذیرش مقاله: ۱۴۰۲/۰۳/۲۱

تاریخ ارسال مقاله: ۱۴۰۲/۰۲/۱۵

فتوولتاییک خورشیدی توضیح داده شده و مروری بر انواع مختلف سلول‌های خورشیدی و آینده آن‌ها انجام شده است. در [۲] نیز مروری بر انواع مختلف سلول‌های خورشیدی فتوولتاییک صورت گرفته است. در [۳] تحلیل قابلیت اطمینان سیستم فتوولتاییک برای استفاده در یک ساختمان صورت گرفته است. در این مقاله مدل DC به DC، مدل AC به DC و اینورتر همواره سالم در نظر گرفته شده‌اند، اما سایر تجهیزات شامل بار، باتری و ماژول‌های فتوولتاییک در برخی ساعات در دسترس نیستند. در [۴] کارکرد طولانی مدت و همچنین قابلیت اطمینان ماژول‌های فتوولتاییک در شرایط آب و هوای گرمسیری ساهاران مورد بررسی قرار گرفته است. در [۵] با استفاده از روش مونت کارلو قابلیت اطمینان سیستم فتوولتاییک مورد ارزیابی قرار گرفته است. در این مقاله نرخ خرابی تجهیزات مختلف تشکیل دهنده سیستم فتوولتاییک با در نظر گرفتن اثر تغییرات شرایط آب و هوایی به دست آورده شده است. در [۶] مطالعه بهره‌برداری سیستم قدرت با حضور نیروگاه‌های بادی و خورشیدی مقیاس بزرگ صورت گرفته و میزان رزرو چرخان مورد نیاز در این شبکه قدرت بر اساس شاخص ریسک محاسبه شده است. در [۷] قابلیت اطمینان یک ریزشبه متشکل از واحدهای بادی، جزومدی جریان و سیستم فتوولتاییک مورد بررسی قرار گرفته است. در [۸] کفایت سیستم قدرت با حضور مزارع فتوولتاییک مقیاس بزرگ مورد ارزیابی قرار گرفته است. در [۹] تاثیر استفاده از سیستم‌های ردیاب مختلف بر عملکرد سیستم فتوولتاییک مورد بررسی قرار گرفته است. در اینجا نیز سه حالت مورد بررسی قرار گرفته است: حالت بدون ردیاب و پنل ثابت، حالت مجهز به ردیاب تک محوره و حالت مجهز به ردیاب دو محوره. در [۱۰] یک روش کنترلی مبتنی بر دنبال نمودن نقطه توان اکتیو برای نیروگاه‌های فتوولتاییک پیشنهاد شده است تا بتوان فرکانس اولیه ریزشبه‌های AC را در شرایطی که سهم نیروگاه‌های فتوولتاییک در تامین برق مورد نیاز ریزشبه قابل توجه است تنظیم نمود. در [۱۱] طراحی یک سیستم متشکل از پنل فتوولتاییک و سلف ابرسانا در یک ریزشبه که دارای نوسانات توان زیادی می‌باشد صورت گرفته است تا بتواند کنترل بر روی فیلتر نمودن هارمونیک‌های مختلف داشته باشد. در [۱۲] سیستم‌های مختلفی که می‌توانند به منظور پمپ نمودن آب در مکان دور از شبکه مورد استفاده قرار بگیرند مورد بررسی قرار گرفته است. این سیستم‌ها شامل توربین بادی، پنل فتوولتاییک و سیستم هیبرید متشکل از توربین بادی و پنل فتوولتاییک می‌باشند.

همان‌گونه که در مرور مقالات مشخص است تاکنون مطالعه بهره‌برداری مبتنی بر مدل سلامت سیستم قدرت با حضور نیروگاه‌های فتوولتاییک انجام نشده است. بر اساس اهدافی که این مقاله دنبال می‌کند سازماندهی آن به صورت زیر خواهد بود: در بخش دوم نیروگاه‌های فتوولتاییک و در بخش سوم مطالعه بهره‌برداری سیستم قدرت با حضور این نیروگاه‌ها بر اساس مدل سلامت تشریح می‌گردد. نتایج شبیه‌سازی و نتیجه‌گیری مقاله در بخش چهارم و پنجم آورده می‌شود.

امروزه اهمیت برقراری تعادل بین تولید و مصرف انرژی الکتریکی بر متخصصان صنعت برق پوشیده نیست. ثابت و در محدوده مجاز قرار گرفتن فرکانس برق در شبکه‌های قدرت مستلزم این است که به همان اندازه که توان الکتریکی توسط نیروگاه‌های مختلف تولید می‌گردد، توان الکتریکی مصرف شود. از طرف دیگر شبکه قدرت در معرض حوادث مختلفی از جمله خروج واحدهای تولید، خرابی خطوط انتقال الکتریکی و سایر تجهیزات می‌باشد که ممکن است تهدیدی برای برهم زدن این تعادل باشد. لذا به منظور جلوگیری از قطعی بار معمولا مقداری رزرو چرخان در شبکه قدرت قرار می‌دهند. این امر سبب می‌شود با بروز اغتشاش در شبکه قدرت نیروگاه‌های که توان تولیدی آن‌ها کمتر از ظرفیت نامی‌شان است توان تولیدی خود را افزایش داده و کمبود توان مورد نیاز را جبران نمایند. برای در نظر گرفتن میزان رزرو چرخان مورد نیاز از گذشته تاکنون روش‌های مختلفی دنبال شده است. در گذشته میزان رزرو چرخان را به اندازه بزرگترین واحد تولیدی سنکرون در شبکه و یا درصدی از آن در نظر می‌گرفتند. این امر منجر می‌شد که سیستم قدرت یا بیش از اندازه قابل اعتماد باشد که اقتصادی نیست و یا اینکه قابلیت اطمینان این سیستم کم باشد. لذا در این مقاله با استفاده از روشی موسوم به روش PJM میزان رزرو چرخان مورد نیاز در شبکه محاسبه می‌شود که برای محاسبه این رزرو وضعیت واحدهای تولید موجود در شبکه قدرت لحاظ می‌گردد. از طرف دیگر کشورهای مختلف جهان در برنامه‌ریزی توسعه تولید خود چند سالی است که نگاه ویژه‌ای به منابع انرژی تجدیدپذیر دارند و درصدد جایگزین نمودن منابع مبتنی بر سوخت‌های فسیلی با منابع انرژی پاک و تجدیدپذیر هستند. نیروگاه‌هایی که در سال‌های اخیر در نقاط مختلف جهان به بهره‌برداری رسیده است از منابع انرژی تجدیدپذیر باد، خورشید، جزرومد، امواج و زیست توده که تجدیدپذیر و پاک هستند استفاده می‌کنند. این نیروگاه‌ها در عین داشتن مزایای فراوان دارای یک مشکل اساسی هستند و آن این است که توان تولیدی این نیروگاه‌ها متغیر با زمان است. به عنوان نمونه در نیروگاه‌های فتوولتاییک توان خروجی پنل‌های فتوولتاییک به میزان تابش خورشید وابسته است و چون در طول روز، ماه و سال شدت تابش خورشید به صورت گسترده تغییر می‌کند توان خروجی این نیروگاه‌ها نیز متغیر با زمان خواهد بود. لذا به دلیل این عدم قطعیت برقراری تعادل تولید و مصرف در شبکه‌های قدرتی که نیروگاه‌های فتوولتاییک در آن‌ها سهم قابل توجهی را در تولید توان دارا می‌باشند چالش بیشتری خواهد داشت. بنابراین در این مقاله پیشنهاد شده است میزان رزرو مورد نیاز در سیستم قدرت با حضور نیروگاه فتوولتاییک بر اساس مدل سلامت تعیین گردد. با توجه به اهمیت موضوع تاکنون کارهای زیادی در زمینه نیروگاه‌های فتوولتاییک و سایر منابع انرژی تجدیدپذیر و مطالعه بهره‌برداری آن‌ها انجام شده است. در [۱] تکنولوژی سیستم

## ۲- نیروگاه فتوولتاییک

عملکرد به دست می‌آورد. احتمال خراب بودن یک نیروگاه که مبتنی بر مدل مارکوف دو حالت می‌باشد در زمان عملکرد  $T$  عبارت است از:

$$P(\text{down}) = \frac{\lambda}{\lambda + \mu} - \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)T} \quad (1)$$

در این روابط لاندا نرخ خرابی و میو نرخ تعمیر می‌باشد. با توجه به اینکه مدت زمان بهره‌برداری کوتاه است امکان انجام تعمیر وجود ندارد و لذا از نرخ تعمیر صرف‌نظر می‌گردد. بنابراین نتیجه می‌شود:


$$P(\text{down}) = 1 - e^{-\lambda T}, \lambda T \ll 1 \quad (2)$$

$$\Rightarrow P(\text{down}) = \text{ORR} = \lambda T$$


این رابطه احتمال خراب بودن یک نیروگاه در زمان عملکرد است. برای نیروگاه‌هایی که دارای مدل مارکوف دو حالت هستند از این رابطه می‌توان استفاده نمود و احتمال خرابی آن‌ها را تعیین کرد. با توجه به اینکه ممکن است شبکه قدرت از تعدادی نیروگاه تشکیل شده باشد بایستی برای همه نیروگاه‌ها احتمال سالم بودن و احتمال خراب بودن را به دست آورد و از ترکیب مدل این نیروگاه‌ها، جدول کلی سیستم قدرت که شامل ظرفیت هر حالت و احتمال مربوطه می‌باشد به دست آورده شود.

### ۲-۳- روش پیشنهادی

در مدل سلامت سیستم قدرت معیارهای قطعی با معیارهای احتمالاتی ترکیب می‌شوند. این مدل برای انجام مطالعات بهره‌برداری مناسب است. بر اساس این مدل سه حالت سلامت، حاشیه و ریسک برای شبکه قدرت می‌توان در نظر گرفت. در حالت سلامت هم بار سیستم تامین می‌گردد و هم مقدار رزرو از بزرگترین واحد موجود در شبکه بیشتر است. در حالت حاشیه بار سیستم تامین می‌گردد اما میزان رزرو از بزرگترین واحد تولید سنکرون کمتر است. در حالت ریسک نیز بار سیستم تامین نمی‌گردد. در شکل (۲) این مدل نشان داده شده است.



شکل (۱): ساختار مزرعه فتوولتاییک



شکل (۲): حالت‌های سه گانه مدل سلامت

یک سلول فتوولتاییک یک پیوند p-n می‌باشد که بر اثر تابش خورشید به آن برق تولید می‌کند. برق تولیدی این سلول DC بوده و دامنه ولتاژ و جریان تولیدی آن نیز کم می‌باشد. از طریق سری و موازی نمودن سلول‌های خورشیدی هم ولتاژ و هم جریان تولیدی آن‌ها افزایش می‌یابد و ساختاری جدید به نام پنل خورشیدی ایجاد می‌گردد. یک پنل خورشیدی از تعدادی سلول خورشیدی به صورت سری و موازی تشکیل شده و در نتیجه جریان و توان تولیدی آن نسبت به سلول فتوولتاییک بیشتر خواهد بود. از طرف دیگر با افزایش ولتاژ و جریان در یک پنل، توان پنل خورشیدی نیز به همین نسبت بیشتر خواهد بود. هر سلول دارای یک مشخصه جریان - ولتاژ و همچنین توان - ولتاژ می‌باشد. در این مشخصه یک نقطه وجود دارد که توان الکتریکی بیشتری دارد که به آن نقطه کار ماکزیمم سلول یا پنل گفته می‌شود. در صورتی که بتوان پنل خورشیدی را در این نقطه قرار داد، توان تولیدی آن بیشتر خواهد بود. برای اینکه بتوان پنل خورشیدی را در نقطه توان ماکزیمم قرار داد از یک مبدل الکترونیک قدرت DC به DC استفاده می‌شود. به این مبدل، مبدل دنبال کننده توان ماکزیمم گفته می‌شود. به مجموعه شامل چندین پنل فتوولتاییک که به یک مبدل الکترونیک قدرت جهت دنبال کردن ماکزیمم توان متصل شده‌اند، یک زیر آرایه گفته می‌شود. با توجه به اینکه توان تولیدی پنل‌های فتوولتاییک DC می‌باشد در صورتی که تمایل به اتصال برق تولیدی آن‌ها به شبکه قدرت باشد بایستی از یک مبدل الکترونیک قدرت که توان DC را به توان AC تبدیل می‌کند استفاده نمود. به این مبدل، اینورتر گفته می‌شود. به مجموعه شامل چندین زیر آرایه که به یک اینورتر وصل شده‌اند نیز یک آرایه گفته می‌شود. یک مزرعه فتوولتاییک از چندین آرایه تشکیل شده است. در شکل (۱) ساختار یک مزرعه فتوولتاییک نشان داده شده است.

### ۳- مدل سلامت سیستم قدرت با حضور نیروگاه

#### فتوولتاییک

قابلیت اطمینان یک تجهیز به معنای این است که آن تجهیز بتواند وظیفه‌ای را که به آن محول شده است به خوبی انجام دهد. در شبکه قدرت که بایستی برق مشترکین را تامین کند قابلیت اطمینان به معنای تامین برق مشترکین بدون قطعی می‌باشد.

### ۳-۱- مطالعه بهره‌برداری

برای انجام مطالعه بهره‌برداری مبتنی بر قابلیت اطمینان، یکی از معروفترین روش‌ها که در کشور آمریکا در ایالت‌ها پنسیلوانیا، نیوجرسی و مریلند استفاده می‌شده است روش PJM بوده است. این روش احتمال سالم یا خراب بودن نیروگاه‌ها را در زمان مطالعه یا زمان



$$\lambda_{ij} = \frac{N_{ij}}{\sum_{k=1}^m N_{ik}}, i \neq j \quad (4)$$

در این روش باید مشخص نمود که در مدت زمان مطالعه  $t$  چند انتقال اتفاق می‌افتد که برابر است با  $n=t/(\Delta t)$ . بنابراین برای به دست آوردن احتمال حالت‌های مختلف نیروگاه فتوولتاییک بایستی به صورت رابطه (۷) ماتریس اولیه در ماتریس انتقال به توان  $n$  ضرب شود. به این قاعده روش ضرب ماتریسی گفته می‌شود.

$$[P(t)] = [P(0)][P]^n \quad (5)$$

ماتریس  $[P(t)]$  یک ماتریس سطری با  $m$  ستون است که احتمال حالت‌های ۱ تا  $m$  مربوط به مدل قابلیت اطمینان نیروگاه فتوولتاییک را در لحظه  $t$  نشان می‌دهد. با داشتن احتمال حالت‌های  $m$  گانه نیروگاه فتوولتاییک در هر لحظه از زمان  $t$  جدول احتمال ظرفیت‌های این نیروگاه نیز مشخص بوده و با جدول احتمال ظرفیت‌های سایر واحدهای تولید، جدول احتمال ظرفیت‌های مربوط به کل شبکه قدرت که از نیروگاه‌های متداول و نیروگاه فتوولتاییک تشکیل شده است به دست می‌آید. با مقایسه بار سیستم با ظرفیت حالت‌های مختلف این جدول شاخص‌های زیر محاسبه می‌گردد:

- ریسک انتخاب واحد: مجموع احتمال حالت‌هایی است که بار سیستم از توان تولیدی سیستم بیشتر است.

- احتمال حالت سلامت: مجموع احتمال حالت‌هایی است که هم توان تولیدی از بار سیستم بیشتر است و هم به اندازه بزرگترین نیروگاه موجود در مدار رزرو وجود دارد.

- احتمال حالت حاشیه: مجموع احتمال حالت‌هایی است که توان تولیدی سیستم از بار سیستم بیشتر است اما رزرو به اندازه بزرگترین واحد سنکرون شبکه وجود ندارد.

- رزرو چرخان: در تعیین رزرو چرخان به ترتیب اولویت واحدهای تولید به مدار وارد می‌شود. به ازای یک بار مشخص هر بار معیار قابلیت اطمینان سیستم محاسبه می‌شود. اگر این معیار برآورده نشد باز واحد جدید اضافه می‌شود. این روند تا جایی ادامه می‌یابد که معیار قابلیت اطمینان برآورده شود. حال رزرو چرخان به دست می‌آید که با میزان کل تولید منهای بار سیستم برابر است. در تعیین رزرو چرخان می‌توان معیار قابلیت اطمینان را تنها بر اساس ریسک در نظر گرفت. در این حالت آنقدر واحد تولید اضافه می‌شود تا ریسک از مقدار مجاز کمتر شود. اما اگر معیار قابلیت اطمینان بر اساس مدل سلامت باشد بایستی آنقدر نیروگاه به سیستم اضافه شود تا احتمال حالت سلامت از مقدار مجاز بیشتر و ریسک از مقدار مجاز کمتر شود.

### ۳-۳- مدل قابلیت اطمینان نیروگاه فتوولتاییک

با توجه به اینکه نیروگاه فتوولتاییک از پنل‌های فتوولتاییک، مبدل‌های الکترونیک قدرت، ترانسفورماتور و کابل تشکیل شده است خراب شدن هر کدام از این تجهیزات، سبب خراب شدن کل نیروگاه یا کاهش توان

در این قسمت از مقاله روش پیشنهادی برای انجام مطالعه بهره‌برداری یک شبکه قدرت که در آن نیروگاه فتوولتاییک نیز وجود داشته باشد تشریح می‌گردد. با توجه به اینکه تابش خورشید تغییر می‌کند توان تولیدی نیروگاه فتوولتاییک نیز که به تابش خورشید وابسته است تغییر خواهد کرد و بنابراین امکان نشان دادن نیروگاه فتوولتاییک با دو حالت وجود ندارد و بایستی تعداد حالت‌های مدل قابلیت اطمینان نیروگاه فتوولتاییک را بیشتر از ۲ در نظر گرفت. فرض می‌شود مدل قابلیت اطمینان نیروگاه فتوولتاییک  $m$  حالتی باشد. می‌توان تعداد تغییر از هر حالت به حالت‌های دیگر را شمرد و ماتریس زیر را که نشان دهنده تعداد جابه‌جایی از هر حالت به حالت‌های دیگر است به دست آورد.

$$[P] = \begin{bmatrix} N_{11} & N_{12} & \dots & N_{1m} \\ N_{21} & N_{22} & \dots & N_{2m} \\ \dots & \dots & \dots & \dots \\ N_{m1} & N_{m2} & \dots & N_{mm} \end{bmatrix} \quad (3)$$

در رابطه فوق  $N_{ij}$  برابر با تعداد ساعات یا دفعاتی در سال یا هر مدت زمان دیگر است که تغییر توان تولیدی نیروگاه فتوولتاییک از حالت  $i$ ام به حالت  $j$ ام صورت گرفته است. برای تعیین احتمال هر کدام از این حالت‌ها در زمان  $t$  باید وضعیت نیروگاه فتوولتاییک در ابتدای مطالعه یا  $t=0$  مشخص باشد. در شروع مطالعه مشخص است که تابش خورشید چقدر است و لذا مشخص است که نیروگاه در چه توانی تولید می‌کند. لذا در ماتریس اولیه نیروگاه احتمال مربوط به آن توان ۱ و بقیه احتمال‌ها صفر قرار داده می‌شود. بر این اساس ماتریس اولیه  $[P(0)]$  که نشان می‌دهد در شروع مطالعه نیروگاه چه توانی را تولید می‌کند به دست می‌آید. این امر در (۴) نشان داده شده است. به عبارت دیگر به منظور تعیین ماتریس اولیه نیروگاه می‌توان از این رابطه استفاده کرد.

$$P(0) = [P_{11} \dots P_{1m}] \quad P_{1i} = \begin{cases} 0 & i=1, \dots, m \quad i \neq k \\ 1 & i=k \end{cases} \quad (4)$$

برای محاسبه احتمال هر کدام از حالت‌ها در مدت زمان  $t$  بایستی ابتدا این زمان به پله‌های زمانی کوچکتر  $\Delta t$  تقسیم شود. بنابراین مشخص می‌شود که در زمان  $t$  چند پله زمانی باید طی شود. در هر کدام از این پله‌های زمانی، یک جابه‌جایی اتفاق می‌افتد. لذا برای تعیین احتمال حالت‌ها کافی است ماتریس اولیه در ماتریس انتقال به توان تعداد جابه‌جایی‌ها ضرب شود. البته ابتدا بایستی ماتریس انتقال در مدت زمان برابر با پله زمانی به دست آورد. در (۵) این امر انجام شده است.

$$[P] = \begin{bmatrix} 1 - (\sum_{i=2}^m \lambda_{1i})\Delta t & \lambda_{12}\Delta t & \dots & \lambda_{1m}\Delta t \\ \lambda_{21}\Delta t & 1 - (\sum_{i=1, i \neq 2}^m \lambda_{2i})\Delta t & \dots & \lambda_{2m} \\ \dots & \dots & \dots & \dots \\ \lambda_{m1}\Delta t & \lambda_{m2}\Delta t & \dots & 1 - (\sum_{i=1, i \neq m}^m \lambda_{mi})\Delta t \end{bmatrix} \quad (5)$$

در رابطه فوق داریم:



این صورت توان تولیدی مربوط به آرایه مربوطه صفر خواهد شد. خرابی مبدل می‌تواند به دلیل خراب شدن سویچ‌ها، تایریستور و یا دیودها، سیستم کنترل و ... باشد. با خراب شدن این مبدل گذر به حالت ۴ اتفاق می‌افتد و توان این حالت برابر با  $(G-1)LRMNP_c$  می‌باشد. نرخ خرابی این حالت نیز برابر است با:


$$\lambda_{14} = G \lambda_{DC/AC} \quad (10)$$

در شکل (۳) مدلی که برای نیروگاه فتوولتائیک با در نظر گرفتن خرابی اجزا به دست آورده شده است نمایش داده شده است. در این مرحله باید تغییرات توان خروجی نیروگاه فتوولتائیک که ناشی از تغییر شدت تابش خورشید است در نظر گرفته شود. با توجه به تغییرات تابش خورشید و اینکه توان تولیدی این نیروگاه‌ها به شدت تابش خورشید وابسته است توان تولیدی این نیروگاه‌ها نیز تغییر می‌کند. در شکل (۴) تغییرات شدت تابش خورشید در منطقه کازرون نشان داده شده است.


به همین دلیل تعداد حالت‌های توان در این نیروگاه‌ها زیاد بوده و بایستی به کمک روش‌های خوشه‌بندی این تعداد حالت‌ها را کاهش داد. در اینجا روش خوشه‌بندی فازی پیشنهاد شده است. با فرض اینکه این روش منجر به کاهش تعداد حالت‌ها به  $H$  حالت شود مدل قابلیت اطمینان نیروگاه فتوولتائیک به صورت شکل (۵) خواهد بود.

#### ۴- نتایج شبیه‌سازی

این بخش با شبیه‌سازی سیستم تست RBTS کارایی روش پیشنهادی را بررسی نموده و تاثیر نیروگاه فتوولتائیک بر مطالعات بهره‌برداری را با در نظر گرفتن مدل سلامت سیستم قدرت نشان می‌دهد. یک نیروگاه فتوولتائیک با ظرفیت ۳۰ مگاوات که از ۵۰ آرایه ۶۰۰ کیلوواتی تشکیل شده و در منطقه کازرون نصب شده است مورد مطالعه قرار



شکل (۳): تاثیر خرابی اجزا بر مدل قابلیت اطمینان نیروگاه فتوولتائیک



شکل (۴): شدت تابش ساعت به ساعت خورشید در منطقه کازرون

تولیدی آن می‌گردد. لذا بایستی در مدل قابلیت اطمینان نیروگاه فتوولتائیک، تاثیر خرابی تجهیزات در نظر گرفته شود. از طرف دیگر، احتمال خراب شدن برخی از تجهیزات سیستم فتوولتائیک از جمله پنل‌های خورشیدی کم بوده و لذا با دقت خوبی می‌توان از خرابی این تجهیزات صرف‌نظر نمود. در این قسمت خرابی سلول فتوولتائیک، خرابی پنل فتوولتائیک و خرابی اینورتر در نظر گرفته می‌شود. یک مزرعه فتوولتائیک در نظر گرفته می‌شود که از  $G$  آرایه، هر کدام شامل  $L$  زیرآرایه تشکیل شده باشد. در هر زیرآرایه نیز  $R$  پنل با  $M$  شاخه موازی، و هر شاخه شامل  $N$  سلول فرض می‌شود. اگر توان ماکزیمم هر سلول در شرایط تابش نامی  $P_c$  در نظر گرفته شود توان خروجی مزرعه خورشیدی  $GLRMNP_c$  خواهد بود. در این مرحله تاثیر خرابی قسمت‌های مختلف مزرعه فتوولتائیک بر توان خروجی مزرعه در نظر گرفته می‌شود. از آنجا که در مطالعات بهره‌برداری، زمان مطالعه کوتاه است و همچنین مدل مارکوف تنها یک تغییر را در نظر می‌گیرد، تنها خرابی یک تجهیز در نظر گرفته می‌شود. اگر هر کدام از سلول‌های فتوولتائیک که در پنل‌های فتوولتائیک قرار دارند تحت تاثیر تنش‌های حرارتی، مکانیکی و الکتریکی خراب شود، شاخه مربوط به آن سلول نیز خراب شده و جریان مربوط به پنل کاهش یافته و در نتیجه توان به مقدار  $(M-1)N P_c$  کاهش می‌یابد. در زیرآرایه، پنل‌ها با هم سری بوده و قانون جریان  $KCL$  ایجاب می‌کند جریان پنل‌ها با هم برابر باشد. با کم شدن جریان یک پنل، مبدل  $DC/DC$  جریان سایر پنل‌ها را نیز به مقدار جریان پنل دارای شاخه خراب کاهش داده و توان مربوط به آن زیرآرایه به مقدار  $(M-1)RNP_c$  کاهش می‌یابد. لذا توان خروجی مزرعه خورشیدی به مقدار  $(GLM-1)RNP_c$  کاهش می‌یابد. با خراب شدن هر کدام از سلول‌های فتوولتائیک این اتفاق رخ می‌دهد. لذا نرخ گذر برابر است با:

$$\lambda_{12} = GLRMN \lambda_c \quad (8)$$

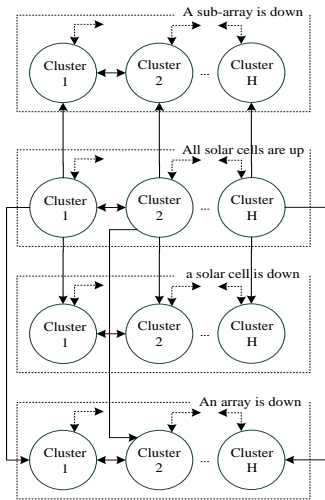
ممکن است به دلایلی مانند بارش برف و تگرگ بر روی پنل، شکسته شدن پایه پنل و ... کل پنل خراب شود که به این خطاها، خطای مشترک گفته می‌شود. در صورت خراب شدن پنل، توان خروجی زیرآرایه صفر می‌شود؛ زیرا در یک زیرآرایه، پنل‌ها با هم سری هستند. همچنین در صورت خراب شدن مبدل  $DC/DC$  نیز توان خروجی زیرآرایه صفر خواهد شد. خرابی مبدل می‌تواند به دلیل خرابی سویچ‌ها، سیستم کنترل و درایو سویچ‌ها و سایر اجزا بروز کند. بنابراین با نرخ گذری برابر با مجموع نرخ خرابی مبدل  $DC/DC$  و نرخ خطای مشترک پنل، توان مربوط به یکی از زیرآرایه‌ها صفر شده و گذر از حالت ۱ به ۳ در مدل نشان داده شده در شکل (۳) اتفاق می‌افتد. ظرفیت حالت ۳ به مقدار توان یک زیرآرایه از حالت ۱ کمتر بوده و برابر با  $(GL-1)RMNP_c$  می‌باشد. نرخ گذر حالت ۱ به ۳ برابر است با:

$$\lambda_{13} = G.L.R.\lambda_{common-panel} + G.L.\lambda_{DC/DC} \quad (9)$$


ممکن است یکی از مبدل‌های  $DC/AC$  یا همان اینورترها که توان  $DC$  را به توان  $AC$  جهت اتصال به شبکه تبدیل می‌کنند خراب شود و در




نیروگاه فتوولتاییک در مقایسه با نرخ انتقال بین حالت‌های هفت گانه از خرابی اجزا صرف نظر شده است.



شکل (۵): مدل نهایی نیروگاه فتوولتاییک به لحاظ قابلیت اطمینان



شکل (۶): نمودار تابع هدف بر حسب تعداد خوشه‌ها



شکل (۷): مدل ۷ حالتی نیروگاه فتوولتاییک ۳۰ مگاواتی

جدول (۱): مرکز خوشه‌ها


شماره خوشه‌ها	مرکز خوشه بر حسب مگاوات
۱	۳۰
۲	۲۶
۳	۲۳
۴	۱۸
۵	۱۲
۶	۶
۷	۰

می‌گیرد. در این نیروگاه هر آرایه فتوولتاییک نیز شامل ۵۰ زیرآرایه ۱۲ کیلوواتی و هر زیر آرایه فتوولتاییک نیز شامل ۴۰ پنل ۳۰۰ وات می‌باشد. پنل فتوولتاییک نیز از ۳ شاخه موازی که هر شاخه از ۳۲ سلول فتوولتاییک سری ساخته شده است تشکیل شده است. ظرفیت هر کدام از میدل‌های DC به DC که برای دنبال کردن ماکزیمم توان استفاده شده‌اند برابر با ۱۲ کیلووات بوده و بنابراین ظرفیت هر کدام از اینورترها برابر با ۶۰۰ کیلووات می‌باشد. در این نیروگاه بازده پنل‌های فتوولتاییک ۱۸/۴ درصد و بازده تجهیزات دیگر شامل میدل‌ها، سیم و اتصالات ۹۰ درصد در نظر گرفته شده است. پنل فتوولتاییک دارای مساحت ۲ مترمربع در نظر گرفته شده و با شدت تابش خورشید ۹۰۰ وات بر مترمربع توان خروجی هر پنل فتوولتاییک در مزرعه فتوولتاییک ۳۰۰ وات می‌باشد. بنابراین اگر شدت تابش خورشید نامی ۹۰۰ وات بر مترمربع بتابد توان خروجی مزرعه فتوولتاییک ۳۰ مگاوات خواهد بود. این مزرعه فتوولتاییک در منطقه کارزون نصب شده است. داده‌های تابش ساعت به ساعت مربوط به این منطقه در شکل (۵) رسم شده است. با داشتن مساحت و بازده پنل‌ها و شدت تابش هر ساعت می‌توان توان این نیروگاه را در هر ساعت محاسبه نمود. با توجه به اینکه شدت تابش خورشید تغییرات زیادی دارد توان تولیدی نیروگاه فتوولتاییک نیز تغییرات زیادی خواهد داشت و به کمک الگوریتم خوشه‌بندی فازی تعداد حالات توان کاهش می‌یابد. در الگوریتم خوشه‌بندی فازی بایستی تعداد خوشه‌ها مشخص باشد. به همین خاطر نمودار تابع هدف بر حسب خوشه‌ها محاسبه شده و در شکل (۶) رسم شده است. همانگونه که در شکل مشخص است زمانی که تعداد خوشه‌ها از ۱ تا ۷ تغییر می‌کند مقدار تابع هدف کاهش می‌یابد و میزان کاهش تابع هدف ملموس است. اما با افزایش تعداد خوشه‌ها به بیشتر از ۷ کاهش تابع هدف دیگر ملموس نیست و به اصطلاح کاهش تابع هدف متوقف شده است. بنابراین می‌توان تعداد ۷ خوشه را برای مدل قابلیت اطمینان نیروگاه فتوولتاییک به کار برد. ماتریس انتقال بین این ۷ حالت به صورت زیر محاسبه شده است:


$$\lambda = \begin{bmatrix} 0.6991 & 0.2663 & 0.0213 & 0.0053 & 0.0080 & 0 & 0 \\ 0.1755 & 0.5135 & 0.2266 & 0.0706 & 0.0111 & 0.0027 & 0 \\ 0.0254 & 0.2516 & 0.4037 & 0.1903 & 0.1078 & 0.0201 & 0.0011 \\ 0.0099 & 0.1176 & 0.3212 & 0.1440 & 0.1656 & 0.2003 & 0.0414 \\ 0.0116 & 0.0252 & 0.1818 & 0.2805 & 0.0967 & 0.1044 & 0.2998 \\ 0.0024 & 0.0048 & 0.0384 & 0.1799 & 0.2326 & 0.0839 & 0.4580 \\ 0 & 0 & 0 & 0.0083 & 0.0337 & 0.0416 & 0.9164 \end{bmatrix}$$

همچنین مرکز خوشه‌های هفت گانه‌ای که برای این نیروگاه به دست آورده شده به صورت جدول (۱) خواهد بود. مدل قابلیت اطمینان این نیروگاه نیز در شکل (۷) نشان داده شده است. با توجه به ماتریس انتقال بین این ۷ حالت و داشتن مرکز خوشه‌ها می‌توان محاسبات مربوط به بهره‌برداری سیستم قدرت با حضور این نیروگاه فتوولتاییک را انجام داد. در ادامه این بخش از مدل قابلیت اطمینان به دست آمده برای نیروگاه فتوولتاییک به منظور انجام مطالعه بهره‌برداری مبتنی بر مدل سلامت سیستم تست *RBTS* استفاده می‌شود. با توجه به پایین بودن نرخ خرابی







شکل (۸): احتمال حالت سلامت در زمان عملکرد ۱ ساعت



شکل (۹): احتمال حالت حاشیه در زمان عملکرد ۱ ساعت




شکل (۱۰): ریسک سیستم در زمان عملکرد ۱ ساعت



شکل (۱۱): مقدار ظرفیت نیروگاه‌های به مدار آورده شده جهت تامین

ملزومات شاخص‌های مدل سلامت



شکل (۱۲): اثر نیروگاه فتوولتائیک بر رزرو چرخان بر اساس شاخص-

های مدل سلامت

به منظور انجام مطالعه بهره‌برداری شبکه قدرت بر اساس مدل سلامت ۴ حالت در نظر گرفته می‌شود: حالت اول سیستم اولیه *RBTS* است و در حالت دوم تا چهارم به ترتیب نیروگاه متداول ۳۰ مگاواتی با نرخ خرابی ۵ بار در سال، نیروگاه فتوولتائیک مورد مطالعه با تابش اولیه خورشید زیاد و نیروگاه فتوولتائیک مورد مطالعه با تابش اولیه خورشید کم به این سیستم اضافه می‌شود. در شکل‌های (۸-۱۰) احتمال سه گانه مدل سلامت یعنی احتمال حالت سلامت، احتمال حالت حاشیه و احتمال حالت ریسک مربوط به زمان عملکرد ۱ ساعت آورده شده است. همانگونه که مشخص است اضافه نمودن نیروگاه فتوولتائیک احتمال حالت سلامت را افزایش و ریسک را کاهش می‌دهد. اما در صورتی که تابش اولیه خورشید کم باشد این نیروگاه‌ها تاثیر کمتری بر شاخص‌های مدل سلامت دارند. در صورتی که تابش اولیه خورشید بیشتر باشد تاثیر این نیروگاه‌ها در بهبود احتمال حالت سلامت و کاهش ریسک سیستم بیشتر خواهد بود. بنابراین به دلیل تغییر نمودن تابش خورشید، در مطالعات بهره‌برداری که مدت زمان مطالعه کم است، میزان تابش خورشید و توان تولیدی نیروگاه فتوولتائیک در شروع مطالعه مهم است. از طرف دیگر تاثیر نیروگاه فتوولتائیک در مقایسه با نیروگاه متداول که توان ثابتی دارد کمتر است زیرا توان تولیدی نیروگاه فتوولتائیک در طول زمان متغیر بوده و در بیشتر اوقات از توان نامی نیروگاه کمتر است. بنابراین بایستی سعی گردد نیروگاه‌های فتوولتائیک در مناطقی که تابش خورشید بالایی دارند نصب گردند تا تاثیر بیشتری بر شاخص‌های مدل سلامت سیستم قدرت داشته باشند. از طرف دیگر همان‌گونه که مشخص است با زیاد شدن بار سیستم، احتمال حالت سلامت کاهش می‌یابد و احتمال حالت ریسک افزایش می‌یابد. بنابراین در صورتی که خواسته شود احتمال حالت سلامت از یک مقدار مجاز کمتر نشود و همچنین ریسک سیستم از مقدار مجاز بیشتر نشود بایستی در بارهای بزرگتر، نیروگاه جدید مانند نیروگاه فتوولتائیک به مدار آورده شود.

در ادامه رزرو چرخان بر اساس شاخص‌های مدل سلامت به دست می‌آید. فرض می‌شود شاخص قابلیت اطمینان مورد نظر به این صورت باشد: ریسک مجاز  $0/00001$  بوده و نباید ریسک از این مقدار بیشتر شود و احتمال حالت سلامت نیز  $0/998$  بوده و نباید احتمال این حالت از این مقدار کمتر شود. حال به ازای بارهای مختلف یکی یکی واحدها به مدار آورده و هر بار این دو شاخص به دست می‌آید. در صورتی که این دو شاخص برآورده نشود واحد جدید بر اساس اولویت ورود به سیستم وارد می‌شود تا اینکه این شاخص‌ها برآورده شوند. برای سه حالت: سیستم اولیه *RBTS*، سیستم *RBTS* با نیروگاه فتوولتائیک با تابش اولیه زیاد، و سیستم *RBTS* با نیروگاه فتوولتائیک با تابش اولیه کم به عنوان حالت‌های اول تا سوم در زمان عملکرد ۴ ساعت مقدار ظرفیتی که باید در مدار باشد تا شاخص‌های دوگانه مبتنی بر مدل سلامت برآورده گردند آورده شده است. در شکل (۱۱) نتایج این محاسبات نشان داده شده است.




*PJM* تعمیر یافته که برای تعیین رزرو چرخان از شاخص‌های قابلیت اطمینان مبتنی بر مدل سلامت بهره می‌برد، استفاده شد. برای نیروگاه فتوولتائیک که مدل قابلیت اطمینان آن چند حالت بود جهت تعیین احتمال حالت‌ها از روش ضرب ماتریسی استفاده شد. برای بررسی تاثیر نیروگاه فتوولتائیک بر شاخص‌های مدل سلامت، شبیه‌سازی سیستم تست *RBTS* در نرم‌افزار متلب انجام شد. نتایج حاصل نشان داد نیروگاه متداول نسبت به نیروگاه فتوولتائیک تاثیر بیشتری در بهبود شاخص‌های مدل سلامت داشت زیرا توان تولیدی آن‌ها ثابت بود اما توان تولیدی نیروگاه فتوولتائیک در طول زمان تغییر می‌کرد و در بیشتر مواقع کمتر از توان نامی بود. همچنین در صورتی که تابش اولیه خورشید کم باشد تاثیر نیروگاه فتوولتائیک کم رنگ است اما اگر تابش خورشید زیاد باشد تاثیر نیروگاه فتوولتائیک قابل توجه خواهد بود.

## مراجع

- [1] Dambhare, Mugdha V., Bhavana Butey, and S. V. Moharil. "Solar photovoltaic technology: A review of different types of solar cells and its future trends." *Journal of Physics: Conference Series*. Vol. 1913. No. 1. IOP Publishing, 2021.
- [2] Al-Ezzi, Athil S., and Mohamed Nainar M. Ansari. "Photovoltaic Solar Cells: A Review." *Applied System Innovation* 5.4 (2022): 67.
- [3] Fara, Laurentiu, and Dan Craciunescu. "Reliability analysis of photovoltaic systems for specific applications." *Reliability and Ecological Aspects of Photovoltaic Modules*; Gok, A., Ed (2020): 79-92.
- [4] Atsu, Divine, et al. "Analysis of long-term performance and reliability of PV modules under tropical climatic conditions in sub-Saharan." *Renewable Energy* 162 (2020): 285-295.
- [5] Shahidi Rad, N., M. Niroomand, and R. Hooshmand. "Failure Rate Calculation and Reliability Assessment of a PV System based on Monte-Carlo Simulation Considering Environmental Conditions." *TABRIZ JOURNAL OF ELECTRICAL ENGINEERING* 48.3 (2018): 1215-1225
- [6] Ghaedi, Amir, and Hamed Gorginpour. "Spinning reserve scheduling in power systems containing wind and solar generations." *Electrical Engineering* (2021): 1-20.
- [7] Nargeszar, Ayoub, et al. "Reliability evaluation of the renewable energy-based microgrids considering resource variation." *IET Renewable Power Generation* 17.3 (2023): 507-527.
- [8] Ghaedi, A., et al. "Incorporating Large Photovoltaic Farms in Power Generation System Adequacy Assessment." *Scientia Iranica* 21.3 (2014): 924-934.
- [9] Bazary, Shahriar. "A study on the effects of solar tracking systems on the performance of photovoltaic power plants." *Journal of Power and Energy Engineering* 2.04 (2014): 718.
- [10] Li, Zhongwen, et al. "Adaptive power point tracking control of PV system for primary frequency regulation of AC microgrid with high PV integration." *IEEE Transactions on Power Systems* 36.4 (2021): 3129-3141.
- [11] Wang, Jian, et al. "Design and Performance Analysis of PV-SMES-Based Microgrid Integrated with Power Fluctuation Suppression and Active Filtering Control." *IEEE Transactions on Applied Superconductivity* 31.8 (2021): 1-5.

با توجه به شکل انتظار می‌رود نسبت به حالت تعیین ظرفیت مورد نیاز بر اساس ریسک سیستم، زمانی که شاخص‌های دوگانه مطرح هستند ظرفیت بیشتری باید به مدار آورده شود. از طرف دیگر همان‌گونه که انتظار می‌رود با زیاد شدن بار سیستم، بایستی ظرفیت تولید بیشتری به مدار آورده شود تا شاخص‌های مدل سلامت در مقدار مجاز قرار بگیرند. همچنین اضافه شدن نیروگاه فتوولتائیک به سیستم قدرت، سبب می‌شود نیروگاه‌های کمتری در مدار باشند و بنابراین کاهش ظرفیت مورد نیاز اتفاق می‌افتد. تاثیر نیروگاه‌های فتوولتائیک در شرایطی که تابش خورشید زیاد است قابل توجه است اما در شرایطی که تابش خورشید کم است تاثیر نیروگاه‌های فتوولتائیک بسیار کم رنگ خواهد بود. در شکل (۱۲) نیز رزرو چرخان مورد نیاز برای سه حالت ذکر شده بر اساس شاخص‌های مدل سلامت به دست آورده شده است. به منظور انجام مقایسه، میزان رزرو مورد نیاز بر اساس شاخص ریسک سیستم نیز به دست آورده شده است. در شکل (۱۳) میزان رزرو چرخان در شرایطی که میزان ریسک کمتر از  $0.0001$  باشد برای سه حالت بیان شده آورده شده است. همان‌گونه که از شکل‌های (۱۲-۱۳) مشخص است میزان رزرو مورد نیاز بر اساس شاخص‌های مدل سلامت نسبت به حالتی که شاخص ریسک تنها در نظر گرفته می‌شود بیشتر است، چرا که علاوه بر اینکه بایستی میزان احتمال حالت ریسک از مقدار مجاز کمتر باشد بایستی احتمال حالت سلامت نیز از مقدار مجاز فراتر رود. همان‌گونه که در شکل مشخص است اضافه نمودن نیروگاه فتوولتائیک به سیستم قدرت سبب کاهش میزان رزرو چرخان و در نتیجه کاهش هزینه می‌شود. البته زمانی نیروگاه فتوولتائیک تاثیرگذار است که تابش اولیه خورشید زیاد باشد.



شکل (۱۳): اثر نیروگاه فتوولتائیک بر رزرو چرخان بر اساس ریسک

## ۵- نتیجه‌گیری

در این تحقیق مطالعه بهره‌برداری مبتنی بر مدل سلامت سیستم قدرت با در نظر گرفتن اثر نیروگاه‌های فتوولتائیک انجام شد. ابتدا مدل قابلیت اطمینان نیروگاه فتوولتائیک با در نظر گرفتن خرابی تجهیزات تشکیل دهنده نیروگاه و تغییرات تابش خورشید به دست آورده شد. در مدل قابلیت اطمینان این نیروگاه‌ها، خرابی اجزای تشکیل دهنده شامل پنل‌ها، مبدل‌های الکترونیک قدرت *DC* به *DC* و اینورتر در نظر گرفته شد. در این تحقیق به منظور انجام بهره‌برداری سیستم قدرت از روش



- [12] Angadi, Sachin, et al. "Comprehensive review on solar, wind and hybrid wind-PV water pumping systems-an electrical engineering perspective." CPSS Transactions on Power Electronics and Applications 6.1 (2021): 1-19.



## الگوریتم‌های یادگیری عمیق در فراتفکیک‌پذیری تصاویر

بهار قادری<sup>۱</sup>، حمید آزاد<sup>۲\*</sup>

۱- گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

Bahar.ghaderi60@gmail.com

۲- گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

azad@shirazu.ac.ir

**چکیده:** فراتفکیک‌پذیری تصویر یکی از فرآیندهای مهم پردازش تصویر جهت افزایش وضوح تصاویر و ویدئوها می‌باشد. در سال‌های اخیر، روش‌های مبتنی بر شبکه‌های عصبی عمیق جهت فراتفکیک‌پذیری شاهد پیشرفت قابل توجهی بوده است. هدف این مقاله ارائه یک بررسی جامع در مورد پیشرفت‌های اخیر فراتفکیک‌پذیری تصویر با استفاده از رویکردهای یادگیری عمیق است. در این مقاله، ضمن معرفی مفاهیم فراتفکیک‌پذیری تصویر، به بررسی الگوریتم‌های رایج یادگیری عمیق جهت فراتفکیک‌پذیری، و کاربردهای فراتفکیک‌پذیری پرداخته شده است. علاوه بر این، مجموعه پایگاه‌های داده و معیارهای ارزیابی تشریح داده می‌شود. این مقاله می‌تواند راهگشای محققان پردازش تصویر در فرآیند فراتفکیک‌پذیری باشد. اهتمام نویسندگان بر این بوده است که همه جنبه‌های این فرآیند مورد کاوش قرار گیرد.

**واژه‌های کلیدی:** فراتفکیک‌پذیری، الگوریتم‌های یادگیری عمیق، تصویر با کیفیت، شبکه عصبی کانولوشن.

## Deep Learning Algorithms in Super-Resolution Images

Bahar Ghaderi<sup>1</sup>, Hamid Azad<sup>2\*</sup>

<sup>1</sup> Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

Bahar.ghaderi60@gmail.com

<sup>2</sup> Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

azad@shirazu.ac.ir

### Abstract:

Image super-resolution is one of the important image processing processes to increase the resolution of images and videos. In recent years, methods based on deep neural networks for super-resolution have seen significant progress. The aim of this paper is to provide a comprehensive review on recent developments in super-resolution image using deep learning approaches. In this article, while introducing the concepts of image super-resolution, the common deep learning algorithms for super-resolution and the applications of super-resolution have been investigated. In addition, the set of databases and evaluation criteria are described. This article can open the way for image processing researchers in the super-resolution process. The authors' effort has been to explore all aspects of this process.

**Keywords:** Super-resolution (SR), Deep Learning Algorithms, High Resolution (HR) Image, Low Resolution (LR) Image, Convolutional Neural Network.

DOI: 00.00000/0000

تاریخ چاپ مقاله: ۱۴۰۲/۰۲/۲۷

تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۱۳

نوع مقاله: پژوهشی

تاریخ ارسال مقاله: ۱۴۰۲/۰۱/۰۷

\* نویسنده‌ی مسئول؛ نشانی: ایران - شیراز - دانشگاه آزاد اسلامی شیراز - دانشکده مهندسی - گروه مهندسی برق

## ۱- مقدمه

تقریبی  $I_y$  از تصویر با کیفیت مرجع  $I_x$  و تصویر بی کیفیت  $I_x$  می‌باشد.

$$\hat{I}_y = F(I_x; \theta) \quad (2)$$

که  $F$  مدل فراتفکیک‌پذیری است و  $\theta$  پارامترهای  $F$  می‌باشد. اگرچه فرآیند تخریب ناشناخته است و می‌تواند تحت تأثیر عوامل مختلفی مانند مصنوعات فشرده سازی، تخریب های ناهمسانگرد، نویز حسگر و نویز لکه‌ای قرار گیرد. محققان تلاش می‌کنند تا نقشه تخریب را مدل کنند. اکثراً مطابق (۳) به طور مستقیم تخریب را به عنوان یک عملیات نمونه برداری کوچک مدل می‌کنند.

$$D(I_y; \delta) = (I_y \otimes k) \downarrow_s + n_c \{k, s, \zeta\} \subset \delta \quad (3)$$

$\downarrow_s$  عملگر نمونه برداری پایین با فاکتور مقیاس  $s$  می‌باشد.  $(I_y \otimes k)$  کانولوشن بین کرنل محوشدگی و تصویر با کیفیت  $I_y$  و  $n_c$  مقداری نویز سفید گوسی با انحراف معیار  $\zeta$  می‌باشد. بنابراین تابع هدف فراتفکیک پذیری مطابق (۴) است.

$$\hat{\theta} = \arg_{\theta} \min \mathcal{L}(\hat{I}_y, I_y) + \lambda \varphi(\theta) \quad (4)$$

در (۴)،  $\mathcal{L}(\hat{I}_y, I_y)$  تابع اتلاف بین تصویر با کیفیت  $I_y$  و تصویر با کیفیت مرجع  $\hat{I}_y$  می‌باشد.  $\varphi(\theta)$  ترم منظم سازی و  $\lambda$  پارامتر توازن است. توابع اتلاف مختلفی وجود دارد که محبوب ترین تابع اتلاف برای فرآیند فراتفکیک‌پذیری، خطای میانگین مربعات پیکسلی (اتلاف پیکسل) می‌باشد.

## ۳- الگوریتم‌های رایج یادگیری عمیق در فرآیند

## فراتفکیک پذیری

الگوریتم‌های گوناگونی از شبکه‌های عصبی عمیق جهت فرآیند فراتفکیک‌پذیری تصاویر استفاده شده است که در این بخش، به شرح چند الگوریتم مهم و رایج پرداخته می‌شود.

۳-۱- شبکه عصبی کانولوشن<sup>۳</sup>

شبکه‌های عصبی کانولوشن یکی از مهم ترین روش‌های یادگیری عمیق هستند که در آنها چندین لایه با روشی قدرتمند آموزش می‌بینند [۱۵]. این روش بسیار کارآمد بوده و یکی از رایج ترین روش‌ها در کاربردهای مختلف بینایی ماشین است. این الگوریتم از سه لایه اصلی شامل لایه کانولوشن، لایه ادغام و لایه تماماً متصل تشکیل شده است. لایه کانولوشن هسته اصلی شبکه می‌باشد که تصویر ورودی با کرنل های مختلف کانوالو می‌کند. لایه ادغام بعد از لایه کانولوشن قرار می‌گیرد که جهت کاهش اندازه نگاشت ویژگی‌ها، کاهش حجم محاسباتی و کنترل نویز استفاده می‌شود. لایه کانولوشن و لایه ادغام نسبت به انتقال تصاویر ثابت می‌باشند. لایه آخر این شبکه‌ها، لایه تماماً متصل می‌باشد. لایه ادغام و لایه تماماً متصل جهت فرآیند فراتفکیک‌پذیری

فراتفکیک‌پذیری تصویر، فرآیند بازیابی تصاویر وضوح بالا از تصاویر وضوح پایین می‌باشد [۱]. این فرآیند، مسئله مهم و چالش برانگیز در بینایی کامپیوتر و پردازش تصویر است [۲] و کاربرد گسترده‌ای در دنیای واقعی همچون بازسازی تصاویر پزشکی [۳]، سنجش از دور [۴]، سیستم‌های نظارتی [۵، ۶] و تلویزیون با کیفیت بالا [۷] دارد. روش های فراتفکیک‌پذیری به طور کلی به دو دسته، روش‌های سنتی و روش‌های یادگیری عمیق تقسیم می‌شود [۸]. روش‌های سنتی سال هاست که به طور گسترده استفاده می‌شود اما روش‌های یادگیری عمیق اخیراً استفاده شده‌اند که عملکرد بهتری دارند [۹-۱۲].

با توجه به اهمیت فرآیند فراتفکیک‌پذیری تاکنون مقاله مروری فارسی ارائه نشده است و همچنین تعداد معدودی مقالات انگلیسی وجود دارد که عمدتاً به بررسی روش‌های سنتی یا بررسی روش‌های یادگیری عمیق جهت فرآیند فراتفکیک‌پذیری بر روی نوع خاصی از تصاویر (پزشکی، چهره، سنجش از دور، طبیعی و غیره) پرداخته است [۴، ۵، ۷، ۸، ۱۳، ۱۴]. اهمیت و کاربرد روزافزون فرآیند فراتفکیک‌پذیری نشان می‌دهد که حداقل هر پنج سال یکبار باید یک مقاله مروری در این زمینه نوشته شود تا بتواند راهگشای محققان در جهت ارتقا عملکرد فرآیند فراتفکیک پذیری باشد. موارد ذکر شده، انگیزه بخش نگارش این مقاله در خصوص الگوریتم‌های یادگیری عمیق در فرآیند فراتفکیک پذیری بوده است. هدف این مقاله، تشریح مفهوم فرآیند فراتفکیک پذیری، بررسی الگوریتم‌های رایج یادگیری عمیق در فرآیند فراتفکیک پذیری، تشریح پایگاه تصاویر موجود و معیارهای ارزیابی می‌باشد.

سازمان‌دهی مقاله به این صورت است که در بخش دوم به بررسی فرآیند فراتفکیک‌پذیری و در بخش سوم به شرح الگوریتم‌های رایج یادگیری عمیق در فرآیند فراتفکیک‌پذیری پرداخته می‌شود. پایگاه‌های داده رایج، معیارهای ارزیابی، و کاربرد فراتفکیک‌پذیری به ترتیب در بخش چهارم، پنجم و ششم بررسی می‌شود. در بخش هفتم به جمع‌بندی و جهت‌دهی به آینده پرداخته می‌شود.

## ۲- فرآیند فراتفکیک‌پذیری

فرآیند فراتفکیک‌پذیری، تبدیل تصاویر بی کیفیت (کیفیت پایین) به تصاویر با کیفیت می‌باشد. فرآیند تخریب مطابق فرمول (۱) می‌باشد.

$$I_x = D(I_y; \delta) \quad (1)$$

در (۱)،  $D$  تابع تخریب و  $\delta$  پارامترهای تخریب می‌باشد. در سناریوی دنیای واقعی، فقط  $I_x$  در دسترس است در حالی که هیچ اطلاعی درباره فرآیند تخریب یا پارامترهای تخریب وجود ندارد. هدف فراتفکیک‌پذیری، حذف اثر تخریب است و بازیابی تصاویر با کیفیت

<sup>3</sup> Convolutional Neural Network (CNN)

<sup>1</sup>High-Resolution (HR) Image

<sup>2</sup> Ground Truth HR Image



لازم نمی‌باشد، یعنی در این فرآیند تنها لایه کانولوشن کاربرد دارد [۱۶]. در هر شبکه عصبی کانولوشن دو مرحله آموزش وجود دارد، انتشار به جلو و پس‌انتشار که در مرحله انتشار به جلو تصویر ورودی وارد شبکه می‌شود. سپس عملیات کانولوشن انجام می‌شود و در نهایت خروجی شبکه محاسبه می‌شود. در این مرحله، نرخ خطای شبکه محاسبه می‌شود تا پارامترهای شبکه در مرحله بعدی تنظیم شوند. در مرحله پس‌انتشار، گرادیان هر پارامتر بر اساس قانون زنجیره محاسبه می‌شود و پارامترها با توجه به تأثیر روی خطای ایجاد شده در شبکه تغییر می‌کنند. در این شبکه، آموزش شبکه پس از انجام تعداد مناسب این مراحل به پایان می‌رسند.

در [۱۷]، شبکه عصبی کانولوشن جهت فراتفکیک‌پذیری تصاویر سی‌تی‌اسکن قفسه سینه معرفی شده است. در [۱۸]، روش شبکه‌های عصبی کانولوشن جهت فراتفکیک‌پذیری تصاویر ماهواره‌ای استفاده شده است. در [۱۹]، شبکه عصبی عمیق جهت فراتفکیک‌پذیری تصاویر کولونوسکوپی استفاده شده است. در [۲۰]، شبکه عصبی کانولوشنی، شبکه عمیق cascade و شبکه‌های کدبندی تُنک<sup>۱</sup> جهت فرآیند فراتفکیک‌پذیری تصاویر ماهواره‌ای بررسی شده است که شبکه عمیق cascade از نظر دقت هم‌ترازی و نسبت سیگنال به نویز عملکرد بهتری دارد. در [۲۱]، شبکه عصبی کانولوشن را جهت فراتفکیک‌پذیری تصویر بهبود داده است. در این روش جهت کاهش تعداد پارامترها از سه بلوک فرعی، بلوک استخراج و بهبود اطلاعات، بلوک بازسازی و بلوک پالایش اطلاعات در شبکه عصبی کانولوشن استفاده می‌کند. در [۲۲]، شبکه عصبی کانولوشن جهت افزایش سرعت در فرآیند فراتفکیک‌پذیری بهبود یافته است. شبکه باقیمانده و اتصال پرش در این شبکه استفاده می‌شود. در [۲۳]، شبکه عصبی کانولوشنی جهت فراتفکیک‌پذیری تصویر ارائه شده است که در این روش، نگاشت کلی بین تصاویر ورودی جهت ایجاد تصاویر با کیفیت استفاده می‌شود.

## ۲-۳- شبکه مولد متخاصم<sup>۲</sup>

شبکه‌های مولد متخاصم، تکنیکی از روش‌های یادگیری ماشین محسوب می‌شوند. این الگوریتم در سال ۲۰۱۴ توسط یان گودفلو و همکاران مطرح و سپس در سال‌های اخیر مورد توجه پژوهشگران و فعال حوزه هوش مصنوعی قرار گرفت [۲۴]. در واقع شبکه‌های GAN رویکردی نوین برای مدل‌سازی مولد با بهره‌گیری از روش‌های یادگیری عمیق برپایه شبکه‌های عصبی کانولوشنی است. در ساختار الگوریتم‌های GAN مدل‌سازی مولد یک فعالیت نظارت نشده است، بدین معنی که یادگیری ماشین براساس اکتشاف خودکار و یادگیری قواعد یا الگوهای موجود در داده‌های ورودی می‌باشد. این تکنیک به

نحوی انجام می‌گردد، که مدل می‌تواند برای خلق یا تولید خروجی‌های جدید از داده‌های اصلی به نحوی عمل نماید که خروجی‌ها غیر اصلی شباهت بسیار بی‌نظیری به داده‌های اصلی داشته و در عین حال جدید و غیر تکراری باشند. شبکه‌های مولد تخصصی روشی بسیار هوشمندانه برای آموزش تولید مدل‌های جدید از داده‌های قبلی می‌باشند. در واقع الگوریتم در این روش بدین صورت کار می‌کند که با چهار چوب‌بندی مساله مورد نظر دو زیر مدل می‌سازد، مدل مولدی که وظیفه‌اش تولید نمونه‌های جدید است و دیگری مدل متمایزگر که تلاش می‌نماید تا نمونه‌ها را به عنوان نمونه اصلی و حقیقی یا نمونه جعلی دسته‌بندی نماید. این کار تا آن زمان ادامه پیدا می‌نماید که مدل متمایزگر به دفعات مختلف فریب خورده و دیگر نتواند داده‌های اصلی و غیر اصلی را از هم جدا نماید.

در [۲۵]، روش جدیدی مبتنی بر شبکه‌های مولد متخاصم جهت فراتفکیک‌پذیری تصاویر سی‌تی‌اسکن کووید ۱۹ و تصاویر سی‌تی‌اسکن مغز پیشنهاد شده است. در [۲۶]، شبکه جدیدی به نام شبکه مولد متخاصم جهت فرآیند فراتفکیک‌پذیری تصاویر مغز ارائه شده است. در [۲۷]، شبکه متخاصم مولد چرخه<sup>۳</sup> جهت فرآیند فراتفکیک‌پذیری تصاویر سونوگرافی ارائه شده است که در این روش از چهار نوع تابع اتلاف شامل اتلاف پیکسل، اتلاف ویژگی‌های ادراکی<sup>۴</sup>، اتلاف خصمانه<sup>۵</sup> و اتلاف ثبات چرخه<sup>۶</sup> استفاده شده است. در [۲۸]، شبکه متخاصم مولد تصادفی<sup>۷</sup> جهت فراتفکیک‌پذیری تصاویر همچون تصاویر شبکه‌ای و تصاویر قلب ارائه شده است. در [۲۹]، شبکه متخاصم مولد بهبودیافته<sup>۸</sup> جهت فرآیند فراتفکیک‌پذیری شبکه‌ای ارائه شده است. در این روش تابع اتلافی جدیدی که ترکیبی از توابع اتلاف نسبی خصمانه، اتلاف ادراکی و اتلاف میانگین مربعات خطا است، جهت آموزش شبکه پیشنهاد کرده است. در [۳۰]، شبکه تولید متمایز عمیق<sup>۹</sup> جهت فرآیند فراتفکیک‌پذیری تصاویر چهره ارائه شده است که این روش در تصاویر چهره کیفیت پایین (با تفکیک‌پذیری پایین) عملکرد مناسبی دارد.

## ۳-۳- شبکه عصبی بازگشتی

یکی از الگوریتم‌های یادگیری عمیق که دارای حافظه درونی هستند، شبکه عصبی بازگشتی است [۳۱]. پیش‌فرض سایر الگوریتم‌های یادگیری عمیق اینست که بین داده‌های ورودی شبکه، هیچ گونه وابستگی وجود ندارد و داده‌ها از هم مستقل هستند. شبکه عصبی بازگشتی با داشتن یک حافظه درونی، مناسب مسائلی هستند که داده‌های ورودی آن‌ها به یکدیگر وابسته است و باید به ترتیب ورودی این داده‌ها توجه شود. مدل شبکه عصبی بازگشتی از حافظه درونی خود برای نگهداری داده‌های ورودی قبلی استفاده می‌کند تا بر اساس آن‌ها

<sup>6</sup> Cycle Consistency Loss

<sup>7</sup> Progressive Generative Adversarial Networks

<sup>8</sup> Improved Generative Adversarial Networks

<sup>9</sup> Deep discriminative Generative Network

<sup>1</sup> Sparse Coding Network

<sup>2</sup> Generative Adversarial Networks (GAN)

<sup>3</sup> Cycle Generative Adversarial Network(CycleGAN)

<sup>4</sup> Perceptual Feature Loss

<sup>5</sup> Adversarial Loss



های دیگر شبکه عصبی عمیق، پارامترهای کمتری دارد و عملکرد موفق-تری جهت فرایند فراتفکیک‌پذیری دارد. در [۴۲]، شبکه عصبی کانولوشن-حافظه طولانی کوتاه مدت<sup>۶</sup> جهت فراتفکیک‌پذیری تصاویر ارائه شده است. در [۴۳]، شبکه‌های عصبی حافظه طولانی کوتاه مدت کانولوشن جهت فراتفکیک‌پذیری تصویر پیشنهاد شده است. در [۴۱]، شبکه LSTM کانولوشن دو طرفه<sup>۸</sup> جهت فراتفکیک‌پذیری تصویر سنجش از دور و ماهواره‌ای ارائه شده است. این روش از پارامترهای کمتری استفاده می‌کند اما عملکرد مناسب‌تری نسبت به روش‌های کلاسیک دارد. در [۴۴]، روشی مبتنی بر شبکه حافظه طولانی کوتاه مدت جهت فراتفکیک‌پذیری تصاویر فراطیفی پیشنهاد شده است. این روش، ویژگی‌های فضایی و ویژگی‌های طیفی تصاویر فراطیفی را در نظر می‌گیرد که از جهت دقت فرایند فراتفکیک‌پذیری عملکرد بهتری دارد.

### ۳-۵- شبکه باقیمانده

شبکه باقیمانده توسط شیوکینگ رن و همکاران در سال ۲۰۱۵ ارائه شده است. شبکه عصبی باقیمانده جهت حل مشکل انفجار گرادیان از لایه‌های پرشی و میانبر بین لایه‌ها استفاده می‌کند [۴۵]. این شبکه در ساختار پایه شامل ۳۴ لایه ساده با معماری VGGNet است که به آن اتصالات میان‌بر اضافه شده است. شبکه عصبی باقیمانده در نسخه-های ۵۰، ۱۰۱ و ۱۵۲ لایه هم وجود دارد. در [۴۶]، شبکه عصبی باقیمانده چند مقیاسی<sup>۹</sup> و تابع هدف خطای میانگین مربعات<sup>۱۰</sup> جهت فراتفکیک‌پذیری تصاویر ماهواره‌ای پیشنهاد شده است. این روش سبب می‌شود، اطلاعات فرکانس بالا در تصاویر همچون لبه‌ها و بافت‌ها حفظ شوند. در [۴۷]، شبکه عصبی باقیمانده جهت فراتفکیک‌پذیری تصاویر MRI ارائه شده است. در این روش، درون‌یابی دو مکعبی با یک لایه دکانولوشن جهت یادگیری فیلترهای نمونه‌برداری بالا استفاده می‌شود و از لایه‌های اتصال پرش باقیمانده با بلوک Inception جهت باز یابی تصویر با کیفیت از تصویر بی کیفیت به کار گرفته می‌شود. در [۴۸]، روش مبتنی بر شبکه عصبی باقیمانده جهت فرایند فراتفکیک‌پذیری پیشنهاد شده است. در این روش، ابتدا تصویر ورودی توسط تبدیل موجک گسسته به چهار زیر تصویر تجزیه می‌شود و سپس ضرایب چهار زیر تصویر به شبکه عصبی باقیمانده داده می‌شوند و در نهایت از معکوس تبدیل موجک گسسته جهت باز یابی تصویر با کیفیت استفاده می‌شود. در [۴۹]، رویکرد جدیدی مبتنی بر شبکه باقیمانده جهت فراتفکیک‌پذیری تصاویر ارائه شده است. شبکه متراکم با توجه کانال باقیمانده عمیق<sup>۱۱</sup> از اتصالات متراکم بین گروه‌های باقیمانده استفاده می‌کند که این روش عملکرد خوبی دارد.

به یادگیری داده جدید بپردازد. شبکه‌های بازگشتی شامل شبکه کانولوشن بازگشتی عمیق، شبکه باقیمانده بازگشتی عمیق و شبکه فراتفکیک‌پذیری هرم لاپلاسی عمیق<sup>۱</sup> به طور گسترده در فرایند فراتفکیک‌پذیری استفاده شده است.

در [۳۲]، مدل DRRCAN<sup>۲</sup> جهت فراتفکیک‌پذیری تصویر پیشنهاد شده است. در این روش با استفاده از بلوک بازگشتی سبب کاهش تعداد پارامترها و با استفاده از ماژول باقیمانده و اتصالات پرش سبب جلوگیری انفجار گرادیان، بهبود پایداری و توانایی تعمیم مدل می‌شود. در [۳۳]، شبکه عصبی بازگشتی جهت فراتفکیک‌پذیری استفاده شده است که این روش در برابر پایگاه داده واقعی و مصنوعی عملکرد موفق دارد. در [۳۴]، شبکه عصبی بازگشتی دو حالتی<sup>۳</sup> جهت فراتفکیک‌پذیری تصویر ارائه شده است. این روش نسبت به روش شبکه عصبی بازگشتی تک حالتی<sup>۴</sup> از جهت دقت عملکرد بهتری دارد. در [۳۵]، شبکه سه بعدی شبه بازگشتی دو طرفه<sup>۵</sup> برای فراتفکیک‌پذیری تصاویر فراطیفی ارائه شده است. این رویکرد دقت باز یابی و کیفیت بصری موثری دارد. در [۳۶]، شبکه عصبی بازگشتی جهت فراتفکیک‌پذیری تصاویر سنجش از دور استفاده شده است و این روش نسبت به روش‌های کلاسیک عملکرد بهتری دارد. در [۳۷]، شبکه بازگشتی عمیق جهت فرایند فراتفکیک‌پذیری پیشنهاد شده است. این روش جهت کاهش دشواری‌های آموزش از نظارت بازگشتی و اتصال پرش استفاده می‌کند. در [۳۸]، شبکه فراتفکیک‌پذیری هرم لاپلاسی عمیق ارائه شده است. این روش جزء شبکه عصبی بازگشتی می‌باشد که از نظر زمان اجرا و کیفیت فرایند فراتفکیک‌پذیری عملکرد مناسبی دارد.

### ۳-۴- شبکه حافظه طولانی کوتاه مدت<sup>۶</sup>

شبکه‌های حافظه طولانی کوتاه مدت توسط هوکرایتر و اشمیدوبر در سال ۱۹۹۷ اختراع شدند و رکوردهای دقت را در حوزه‌های کاربردی متعدد ثبت کردند [۳۹، ۴۰]. شبکه حافظه طولانی کوتاه مدت از مشکل انفجار گرادیان جلوگیری می‌کند. شبکه عصبی با حافظه طولانی کوتاه مدت ساختار حلقه‌ای دارد و به ازای تعداد اجزای داده ورودی، عمل یادگیری و پردازش داده‌ها تکرار می‌شود. شبکه عصبی با حافظه طولانی کوتاه مدت داده‌های غیر مرتبط و بی‌اهمیت قبلی را در زمان پردازش داده جدید حذف می‌کند و تنها اطلاعات مهم داده‌های قبلی را در حافظه خود نگه می‌دارد. چنانچه نیاز به بروز رسانی اطلاعات قبلی نیز باشد، این کار توسط توابع درون این شبکه انجام می‌شود.

در [۴۱]، از شبکه حافظه طولانی کوتاه مدت جهت فراتفکیک‌پذیری تصاویر سنجش از دور استفاده شده است. این روش نسبت به الگوریتم-

<sup>6</sup> Long short-term memory (LSTM)

<sup>7</sup> CNN-LSTM network

<sup>8</sup> Bidirectional convolutional LSTM (BiConvLSTM)

<sup>9</sup> Multi-Scale Residual Neural Network (MRNN)

<sup>10</sup> Mean Squared Error

<sup>11</sup> DenseNet with deep Residual Channel Attention (DRCA)

<sup>1</sup> Deep Laplacian Pyramid Super-Resolution Network

<sup>2</sup> Deep Recursive Residual Channel Attention Network (DRRCAN) model

<sup>3</sup> Dual-State Recurrent Network (DSRN)

<sup>4</sup> Single-state recurrent neural network (RNN)

<sup>5</sup> Bidirectional 3D Quasi-Recurrent Neural Network



## ۴- پایگاه‌های داده

مجموعه به ترتیب شامل ۸۸۴، ۷۸۳ و ۸۴۰ جفت تصاویر باکیفیت و بی‌کیفیت در فاکتورهای مقیاس مختلف ۲، ۳ و ۴ می‌باشد.

### • مجموعه City 100

مجموعه City 100 توسط چن و همکاران با دوربین‌های iPhoneX و NikonD5500 تهیه شده است [۵۴]. این مجموعه شامل ۱۰۰ تصویر از صحنه‌های شهری مختلف می‌باشد. تصاویر با کیفیت و بی‌کیفیت با فاصله کانونی متفاوتی گرفته شده‌اند.

### • مجموعه SR-RAW

مجموعه SR-RAW توسط ژانگ و همکاران ایجاد شده است که از هر صحنه، هفت تصویر تحت شرایط زوم مختلف (۲۴-۲۴۰) تهیه شده است [۵۵]. این مجموعه شامل ۵۰۰ توالی هفت تصویر از صحنه‌های داخلی و بیرونی می‌باشد.

### • مجموعه TextZoom

مجموعه تصاویر متنی TextZoom از مجموعه RealSR و SR-RAW نشات گرفته است [۵۶]. تصاویر متنی در این مجموعه از تصاویر صحنه‌های مختلف RealSR و SR-RAW همچون مغازه‌ها، نماهای خیابان، و فضای داخلی خودرو برش داده شده‌اند. تصاویر متنی براساس دشواری به سه سطح، آسان، متوسط و سخت می‌باشد.

### • مجموعه Super

مجموعه Super توسط کوهر و همکاران ایجاد شده است [۵۷]. این مجموعه بیش از ۸۰۰۰ تصویر از ۱۴ صحنه آزمایشگاهی در چهار وضوح و پنج سطح فشرده سازی با دوربین CMOS گرفته شده است.

### • مجموعه ImagePairs

مجموعه ImagePairs توسط جوز و همکاران تهیه شده است که این مجموعه شامل ۱۱۴۲۱ جفت تصاویر با کیفیت و بی‌کیفیت از صحنه‌های مختلف گرفته شده است [۵۸]. این تصاویر با دو دوربین جهت تولید تصاویر با کیفیت و بی‌کیفیت گرفته شده است که فاصله کانونی متفاوتی دارند.

## ۴-۲- پایگاه تصاویر پزشکی

پایگاه‌های داده گوناگونی در مقالات مختلف جهت فرآیند فراتفکیک پذیری تصاویر پزشکی استفاده شده‌اند که تصاویر کیفیت پایین در بعضی از این پایگاه‌های داده به صورت تجربی و در بعضی دیگر شبیه‌سازی شده است. در ادامه چهار پایگاه تصاویر پزشکی جهت فرآیند فراتفکیک‌پذیری به طور مختصر توضیح داده می‌شود.

- پایگاه تصاویر MRI مغز شبیه‌سازی شده که شامل تصویر MRI مغز سالم و تصاویر MRI مغز بیماران مالتیپل اسکلروزیس می‌باشد. این تصاویر MRI در سه مودالیت،  $T_1$ ،  $T_2$  و PD می‌باشد<sup>۴</sup>.

فرآیند فراتفکیک‌پذیری، یک شاخه علمی مهم در پردازش تصویر می‌باشد و برای ارزیابی عملکرد این فرآیند، تعدادی پایگاه داده استاندارد ایجاد شده است. از نظر ماهیت تصاویر، می‌توان این پایگاه‌ها را به چهار دسته، پایگاه تصاویر طبیعی، پزشکی، ماهواره‌ای، و پایگاه تصاویر چهره قابل تقسیم کرده است. در ادامه به بررسی هر یک از انواع پایگاه‌های داده پرداخته می‌شود.

## ۴-۱- پایگاه تصاویر طبیعی

پایگاه داده مختلفی از تصاویر طبیعی وجود دارد که بعضی از این پایگاه‌های داده شامل تصاویر با کیفیت و بی‌کیفیت هستند و بعضی دیگر از آنها تنها تصاویر با کیفیت تامین می‌کنند که تصاویر بی‌کیفیت در آنها می‌توان توسط نرم‌افزارهای مختلف ایجاد کرد. در ادامه به بررسی چند پایگاه داده رایج تصاویر طبیعی پرداخته می‌شود.

### • مجموعه DIV2KRRK

این مجموعه داده آزمایش مصنوعی توسط بیل کیلگر و همکاران ساخته شده است [۵۰]. DIV2KRRK از پایگاه داده DIV2K نشات گرفته است. DIV2K توسط آگوستسون و همکاران ایجاد شد که ۱۰۰ عدد از تصاویر با کیفیت برای ایجاد تصاویر بی‌کیفیت (کیفیت پایین) با کرنل‌های تصادفی محو و نمونه‌برداری می‌شوند [۵۱]. کرنل‌های محوشدگی تصادفی با اندازه  $11 \times 11$  گوسی ناهمسانگرد می‌باشد و هر کدام از آنها با دو طول  $0/6$  و  $5$  توزیع شده مستقل و زاویه چرخش  $\pi$  و  $-\pi$  می‌باشد. مدل تخریب در مجموعه DIV2KRRK، پیچیده‌تر و تصادفی‌تر از مجموعه DIV2K می‌باشد.

### • مجموعه RealSR

مجموعه داده واقعی RealSR توسط چیا و همکاران جمع‌آوری شده است [۵۲]. داده آموزشی و آزمایشی مجموعه شامل ۵۹۵ جفت تصویر باکیفیت و بی‌کیفیت می‌باشد. این تصاویر با فاکتورهای مقیاس مختلف (۲، ۳، ۴) و در چهار طول فاصله کانونی (۲۸ میلی‌متر، ۳۵ میلی‌متر، ۵۰ میلی‌متر و ۱۰۵ میلی‌متر) گرفته شده‌اند. تصاویر در فاصله کانونی ۱۰۵ میلی‌متر به عنوان تصاویر با کیفیت و تصاویر در فواصل کانونی ۲۸ میلی‌متر، ۳۵ میلی‌متر و ۵۰ میلی‌متر به عنوان تصاویر بی‌کیفیت در نظر گرفته شده است.

### • مجموعه DRealSR

مجموعه داده واقعی DRealSR توسط ویی و همکاران گرفته شده است [۵۳]. این مجموعه با پنج دوربین (سونی، کانن<sup>۱</sup>، الپوس<sup>۲</sup>، نیکون<sup>۳</sup> و پاناسونیک) در چهار وضوح از صحنه‌های بیرونی و داخلی (ساختمان‌ها، ادارات، گیاهان، پوسترها و غیره) تهیه شده است. این

<sup>3</sup> Nikon

<sup>4</sup> <http://brainweb.bic.mni.mcgill.ca/brainweb/>

<sup>1</sup> Canon

<sup>2</sup> Olympus



معیارهای ارزیابی مختلف ممکن است لزوماً با یکدیگر و همچنین ارزیابی ذهنی سازگار نباشند [۵۲]. در ادامه، معیارهای ارزیابی رایج عینی مبتنی بر کیفیت شرح داده می‌شود.

#### • نسبت سیگنال به نویز

معیار نسبت سیگنال به نویز مطابق (۵) محاسبه می‌شود. هرچه مقدار این معیار بیشتر، عملکرد فرآیند فراتفکیک پذیری بهتر می‌باشد.

$$PSNR = 10 \log_{10} \left( \frac{M^2}{MSE} \right) \quad (5)$$

در این رابطه،  $M$  ماکزیمم مقدار شدت روشنایی پیکسل (برای مثال برای تصاویر ۸ بیتی، مقدار ۲۵۵) می‌باشد.  $MSE$  میانگین مربعات خطا بین تصویر حاصل فرآیند فراتفکیک‌پذیری و تصویر با کیفیت می‌باشد که (۶) محاسبه می‌شود.

$$MSE = \frac{1}{hwc} \|I_{SR} - I_{HR}\|^2 \quad (6)$$

در این روابط،  $h, w, c$  به ترتیب کانال تصاویر، پهنا و ارتفاع می‌باشد. هرچه تفاضل پیکسل‌های بین دو تصویر (تصویر حاصل فرآیند فراتفکیک‌پذیری و تصویر باکیفیت) کمتر باشد، مقدار نسبت سیگنال به نویز بیشتر و بهتر می‌باشد.

#### • شاخص شباهت ساختاری

معیار شاخص شباهت ساختاری مطابق (۷) محاسبه می‌شود [۵۹].

$$SSIM = l(I_{HR}, I_{SR}) * C(I_{HR}, I_{SR}) * S(I_{HR}, I_{SR}) \quad (7)$$

در این رابطه،  $l(I_{HR}, I_{SR})$ ،  $C(I_{HR}, I_{SR})$  و  $S(I_{HR}, I_{SR})$  به ترتیب شباهت شدت روشنایی، شباهت کنتراست و شباهت ساختاری می‌باشد. هرچه شباهت ساختاری دو تصویر بیشتر باشد، مقدار شاخص شباهت ساختاری بیشتر و بهتر می‌باشد. در [۵۹]، معیارهای ارزیابی نسبت سیگنال به نویز و شاخص شباهت ساختاری بررسی شدند که شاخص شباهت ساختاری کیفیت بصری را بهتر از معیار نسبت سیگنال به نویز منعکس می‌کند.

#### • معیار وفاداری اطلاعات<sup>۱۱</sup>

معیار وفاداری اطلاعات، جزء معیارهای مرجع کامل است که کیفیت تصاویر را بر اساس آمار صحنه‌های طبیعی ارزیابی می‌کند. به طور کلی، تحریف‌ها، آمار صحنه‌های طبیعی را مختل می‌کند و تصاویر را غیرطبیعی نشان می‌دهد. معیار وفاداری اطلاعات، اطلاعات متقابل شرطی بین تصویر منبع و تصویر منحرف شده را مطابق (۸) محاسبه می‌کند [۶۰].

$$IFC = \sum_{k \in \text{subbands}} I(C^{N_k, k}, D^{N_k, k} | S^{N_k, k}) \quad (8)$$

- پایگاه تصاویر MRI مغز می‌باشد که این پایگاه داده در سه دسته، تصاویر MRI مغز افراد سالم، تصاویر MRI مغز بیماران آلزیمری و تصاویر MRI مغز نوزدان نارس می‌باشد. این پایگاه شامل ۳۱۲ تصاویر می‌باشد<sup>۱</sup>.
- پایگاه تصاویر MRI مغز بیماران گلیوما می‌باشد و شامل ۶۵ تصویر می‌باشد<sup>۲</sup>.
- پایگاه تصاویر MRI مغز افراد سالم می‌باشد که این پایگاه از سه بیمارستان مختلف با دستگاه مختلف MRI در لندن جمع‌آوری شده است و تعداد کل این تصاویر تقریباً برابر ۶۰۰ تصویر می‌باشد. این تصاویر در مودالیت‌های  $T_1$ ،  $T_2$  و PD می‌باشد<sup>۳</sup>.

### ۳-۴- پایگاه تصاویر چهره

پایگاه‌های داده گوناگونی جهت فرآیند فراتفکیک‌پذیری تصاویر چهره وجود دارد که پایگاه Helen و پایگاه CelebA-HQ دو نمونه رایج می‌باشد. پایگاه‌های دیگری، جهت فرآیند فراتفکیک‌پذیری استفاده می‌شود<sup>۴</sup>.

### ۴-۴- پایگاه تصاویر سنجش از دور

پایگاه‌های مختلفی جهت فرآیند فراتفکیک‌پذیری تصاویر ماهواره‌ای وجود دارد که در ادامه به شرح پایگاه‌های داده رایج پرداخته می‌شود.

- پایگاه RSSCN7: این پایگاه شامل ۲۸۰۰ تصویر از مناطق مسکونی، صنعتی، جنگل‌ها، زمین‌های کشاورزی، رودخانه‌ها و دریاچه‌ها می‌باشد<sup>۵</sup>.
- پایگاه PIRM: این پایگاه شامل ۲۰۰ تصویر از محیط، مردم، گیاهان، مناظر طبیعی و اشیاء می‌باشد<sup>۶</sup>.
- پایگاه WHURS19: این پایگاه شامل ۱۰۰۵ تصاویر از فرودگاه، پل، جنگل‌ها، مناطق تجاری، مسکونی و صنعتی می‌باشد<sup>۷</sup>.
- پایگاه Kaggle: این پایگاه شامل ۳۲۴ تصویر از ساختمان‌ها، زمین گلف، جنگل‌ها و بندرگاه می‌باشد<sup>۸</sup>.

### ۵- معیارهای ارزیابی

معیارهای ارزیابی کیفیت فرآیند فراتفکیک‌پذیری را می‌توان به طور کلی به دو دسته، ارزیابی ذهنی مبتنی بر ادراک انسانی<sup>۹</sup> و ارزیابی عینی مبتنی بر کیفیت<sup>۱۰</sup> تقسیم کرد. محدودیت‌های ارزیابی ذهنی عبارتند از، نتیجه ارزیابی تحت تأثیر ترجیحات شخصی قرار می‌گیرد، فرآیند ارزیابی اغلب پرهزینه است و نمی‌توان آن را خودکار کرد. در مقابل، ارزیابی عینی برای استفاده راحت‌تر است، اگرچه نتایج با

<sup>7</sup> [http://www.tsi.enst.fr/~xia/satellite\\_image\\_project.html](http://www.tsi.enst.fr/~xia/satellite_image_project.html)

<sup>8</sup> <https://www.kaggle.com/c/drapper-satellite-image-chronology/data>

<sup>9</sup> human perception-based subjective evaluation

<sup>10</sup> quality metrics-based objective evaluation

<sup>11</sup> Information Fidelity Criterion

<sup>1</sup> <https://sites.google.com/site/brainseg/>

<sup>2</sup> <https://www.smir.ch/BRATS/Start2015>

<sup>3</sup> <http://brain-development.org/ixi-dataset/>

<sup>4</sup> <http://vis-www.cs.umass.edu/lfw/>

<sup>5</sup> <https://sites.google.com/site/qinzoucn/documents>

<sup>6</sup> <https://pirm.github.io/>



در این رابطه،  $C^{N_k, k}$  برابر با  $N_k$  تا ضرایب از مدل تصویر منبع از  $k^{th}$  زیر باند می‌باشد و  $D^{N_k, k}$  برابر  $N_k$  تا ضرایب از مدل تصویر منحرف شده از  $k^{th}$  زیر باند می‌باشد.

#### • معیار شباهت وصله تصویر ادراکی آموخته شده<sup>۱</sup>

شباهت وصله تصویر ادراکی آموخته شده جهت ارزیابی کیفیت تصویر مبتنی بر مرجع است [۶۱]. این معیار فواصل بین تصویر مرجع و تصویر آزمایشی در یک فضای ویژگی عمیق محاسبه می‌کند. این معیار بیشتر از معیارهای ارزیابی نسبت سیگنال به نویز و شاخص شباهت ساختاری تطابق با قضاوت‌های انسانی (ارزیابی بصری) دارد. هرچه دو تصویر شبیه‌تر باشند، مقدار این معیار کمتر می‌باشد.

#### • ارزیاب کیفیت تصاویر طبیعی<sup>۲</sup>

ارزیاب کیفیت تصویر طبیعی، یک معیار کاملاً کور بدون آگاهی از قضاوت یا تعریفات انسانی است [۶۲]. به طور خاص، ویژگی‌ها شامل پارامترهای توزیع گوسی تعمیم یافته<sup>۳</sup> و توزیع گوسی تعمیم یافته نامتقارن<sup>۴</sup> است که رفتار تکه‌های تصویر را مشخص می‌کند. سپس، کیفیت یک تصویر با استفاده از فاصله بین دو مدل گوسی چند متغیره متناسب با تصاویر طبیعی و تصویر ارزیابی شده اندازه‌گیری می‌شود.

#### • معیار کیفیت بدن مرجع<sup>۵</sup>

این معیار جهت ارزیابی تصویر فراتفکیک‌پذیری شده استفاده می‌شود. برای پیش‌بینی مقدار ادراکی تصاویر فراتفکیک‌پذیری شده، سه گروه از ویژگی‌های آماری شامل ویژگی‌های فرکانس محلی، ویژگی‌های فرکانس عمومی و ویژگی‌های فضایی استخراج می‌شوند [۶۳].

#### • ارزیاب کیفیت مبتنی بر ادراک<sup>۶</sup>

ارزیاب کیفیت مبتنی بر ادراک، یک معیار ارزیابی کیفیت تصویر بدون مرجع است [۶۴]. با توجه به اینکه توجه سیستم بینایی انسان به شدت به سمت مناطق فعال فضایی معطوف شده است، تصویر آزمایشی به بلوک‌های غیرهمپوشانی تقسیم می‌شود و تجزیه و تحلیل سطح بلوک برای شناسایی اعوجاج و کیفیت درجه انجام می‌شود. بنابراین، ارزیاب کیفیت مبتنی بر ادراک می‌تواند یک نقشه کیفیت فضایی ارائه دهد. کیفیت کلی تصویر ارزیابی شده را می‌توان با ادغام نمرات کیفیت سطح بلوک به دست آورد.

## ۶- کاربرد فراتفکیک‌پذیری

فرآیند فراتفکیک‌پذیری در زندگی روزمره کاربرد گسترده‌ای دارد که در سه دهه اخیر، کاربردهای مختلف آن مورد توجه محققان قرار گرفته است. در ادامه به شرح چند کاربرد مهم این حوزه پرداخته می‌شود.

## ۶-۱- ارتقا اطلاعات ویدیویی

کاربرد تکنیک‌های فراتفکیک‌پذیری به زندگی روزمره وارد شده است. تصاویر ویدیویی بی‌کیفیت را می‌توان با استفاده از این فرآیند به تصاویر ویدیویی با کیفیت تبدیل کرد. هیتاچی با استفاده از فراتفکیک‌پذیری، تبدیل تلویزیون با کیفیت استاندارد<sup>۷</sup> به تلویزیون با کیفیت بالا<sup>۸</sup> را به دست آورد. همین موضوع سبب شد که فراتفکیک‌پذیری را به موضوع تحقیقاتی بسیار جالب و مرتبط تبدیل کند [۶۵].

## ۶-۲- نظارت

امروزه دستگاه‌های ضبط ویدئوی دیجیتال<sup>۹</sup> در همه جا وجود دارند و نقش مهمی در کاربردهایی همچون نظارت بر ترافیک و نظارت بر امنیت ایفا می‌کنند. با این حال، در حال حاضر تجهیز دستگاه‌های منابع انسانی در مقیاس بزرگ غیرممکن است. بنابراین، مطالعه تکنیک‌های تصویر ضروری است. اگرچه تکنیک‌ها به تدریج توسعه یافته‌اند، استفاده عملی از ویدئو فراتفکیک‌پذیری هنوز یک چالش است. اولاً، دستگاه‌های ویدیویی در فضای باز در برابر تأثیر شرایط آب و هوایی آسیب‌پذیر هستند. علاوه بر این، داده‌های ویدیویی معمولاً دارای حجم عظیمی از داده و حرکت پیچیده هستند [۶۶].

## ۶-۳- تشخیص پزشکی

مودالیت‌های مختلف تصویربرداری پزشکی می‌توانند هم اطلاعات تشریحی در مورد ساختار بدن انسان و هم اطلاعات عملکردی را ارائه دهند. با این حال، محدودیت وضوح همیشه ارزش تصاویر پزشکی در تشخیص را کاهش می‌دهد. فناوری فراتفکیک‌پذیری با مودالیت‌های مهم تصویربرداری پزشکی همچون MRI، fMRI و PET استفاده شده- اند [۶۷].

## ۶-۴- رصد نجومی

وضوح فیزیکی دستگاه‌های تصویربرداری نجومی محدود شده توسط پارامترهای سیستم نیز فرصتی را برای تکنیک‌های فراتفکیک‌پذیری برای ایفای نقش فراهم می‌کند [۶۸]. سیستم‌های نجومی معمولاً می‌توانند مجموعه‌ای از تصاویر را برای فراتفکیک‌پذیری جمع‌آوری کنند. با بهبود وضوح تصاویر نجومی، فراتفکیک‌پذیری می‌تواند به اخترشناسان در اکتشاف فضای بیرونی کمک کند.

<sup>6</sup> Perception-based Quality Evaluator (PIQE)

<sup>7</sup> Standard Definition TV (SDTV)

<sup>8</sup> High-Definition Television (HDTV)

<sup>9</sup> Digital Video Recorder (DVR) Devices

<sup>1</sup> The Learned Perceptual Image Patch Similarity (LPIPS)

<sup>2</sup> Natural Image Quality Evaluator (NIQE)

<sup>3</sup> Generalized Gaussian Distribution (GGD)

<sup>4</sup> Asymmetric Generalized Gaussian distribution (AGGD)

<sup>5</sup> Learned no-Reference Quality Metric (NRQM)






## ۶-۵- شناسایی اطلاعات بیومتریک

فرآیند فراتفکیک‌پذیری در تشخیص بیومتریک همچون ارتقای وضوح چهره [۶۹]، اثر انگشت [۷۰] و عنیبه [۷۱] مهم است. وضوح تصاویر بیومتریک در فرآیند شناسایی و تشخیص بسیار مهم است.

## ۷- جمع‌بندی و جهت‌دهی آینده

فراتفکیک‌پذیری تصویر، رویکردی موثر جهت افزایش وضوح فضایی برای کاربردهای متعددی همچون تشخیص اشیاء و طبقه‌بندی می‌باشد. این مقاله به طور خلاصه، الگوریتم‌های رایج یادگیری عمیق همچون شبکه عصبی کانولوشن، شبکه مولد متخاصم، شبکه بازگشتی و شبکه باقیمانده جهت فراتفکیک‌پذیری تصاویر بررسی می‌کند. علاوه بر این، به مجموعه پایگاه‌های داده رایج تصاویر مختلف و معیارهای ارزیابی پرداخته شد. مطالب ارائه شده در این مقاله، پتانسیل بررسی جهت سوگیری تحقیقات در زمینه فراتفکیک‌پذیری را دارد. با توجه به تحقیقات زیادی که در زمینه فراتفکیک‌پذیری انجام شده است، اما هنوز به دلیل متنوع بودن تصاویر و وجود مدل‌های تخریب مختلف در تصاویر، یک روش عمومی و کامل جهت انجام این فرآیند وجود ندارد. بنابراین برای انجام فراتفکیک‌پذیری تصاویر باید به ماهیت تصاویر هم توجه کرد، زیرا مدل‌های تخریب متفاوت بستگی به نوع تصویر دارد. شکل (۱) نمودار تعداد مقالات از پایگاه IEEE در تصاویر متفاوت در محدوده‌ی سال‌های ۲۰۱۵-۲۰۲۳ است. با توجه به این نمودار می‌توان نتیجه گرفت که در آینده زمینه‌های کاری بر روی تصاویر طبیعی و سنجش از دور بیشتر است. همانطور که مشخص شد، کاربردهای فراتفکیک‌پذیری در تصاویر طبیعی و تصاویر سنجش از دور بیشتر از تصاویر دیگر همچون تصاویر متنی و پزشکی مورد اقبال محققین است.



شکل (۱): نمودار تعداد مقالات بر حسب تصاویر مختلف فراتفکیک‌پذیری

## مراجع

- [1] F. Liu, X. Yang, and B. De Baets, "A deep recursive multi-scale feature fusion network for image super-resolution," *Journal of Visual Communication and Image Representation*, vol. 90, p. 103730, 2023.
- [2] L. Inzerillo, F. Acuto, G. Di Mino, and M. Z. Uddin, "Super-resolution images methodology applied to UAV datasets to road pavement monitoring," *Drones*, vol. 6, p. 171, 2022.
- [3] Y. Huang, L. Shao, and A. F. Frangi, "Simultaneous super-resolution and cross-modality synthesis of 3D medical images using weakly-supervised joint convolutional sparse coding," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 6070-6079.
- [4] D. Yang, Z. Li, Y. Xia, and Z. Chen, "Remote sensing image super-resolution: Challenges and approaches," in *2015 IEEE international conference on digital signal processing (DSP)*, 2015, pp. 196-200.
- [5] J. Jiang, C. Wang, X. Liu, and J. Ma, "Deep learning-based face super-resolution: A survey," *ACM Computing Surveys (CSUR)*, vol. 55, pp. 1-36, 2021.
- [6] A. B. Deshmukh and N. Usha Rani, "Fractional-Grey Wolf optimizer-based kernel weighted regression model for multi-view face video super resolution," *International Journal of Machine Learning and Cybernetics*, vol. 10, pp. 859-877, 2019.
- [7] H. Liu, Z. Ruan, P. Zhao, C. Dong, F. Shang, Y. Liu, et al., "Video super-resolution based on deep learning: a comprehensive survey," *Artificial Intelligence Review*, vol. 55, pp. 5981-6035, 2022.
- [8] S. Anwar, S. Khan, and N. Barnes, "A deep journey into super-resolution: A survey," *ACM Computing Surveys (CSUR)*, vol. 53, pp. 1-34, 2020.
- [9] C. Qiao, D. Li, Y. Liu, S. Zhang, K. Liu, C. Liu, et al., "Rationalized deep learning super-resolution microscopy for sustained live imaging of rapid subcellular processes," *Nature biotechnology*, vol. 41, pp. 367-377, 2023.
- [10] M. Chaika, S. Afat, D. Wessling, C. Afat, D. Nickel, S. Kannengiesser, et al., "Deep learning-based super-resolution gradient echo imaging of the pancreas: Improvement of image quality and reduction of acquisition time," *Diagnostic and Interventional Imaging*, vol. 104, pp. 53-59, 2023.
- [11] B. Niu, Q. Feng, J. Yang, B. Chen, B. Gao, J. Liu, et al., "Solid waste mapping based on very high resolution remote sensing imagery and a novel deep learning approach," *Geocarto International*, vol. 38, p. 2164361, 2023.
- [12] G. Liang, U. KinTak, H. Yin, J. Liu, and H. Luo, "Multi-scale hybrid attention graph convolution neural network for remote sensing images super-resolution," *Signal Processing*, vol. 207, p. 108954, 2023.
- [13] W. Yang, X. Zhang, Y. Tian, W. Wang, J.-H. Xue, and Q. Liao, "Deep learning for single image super-resolution: A brief review," *IEEE Transactions on Multimedia*, vol. 21, pp. 3106-3121, 2019.
- [14] Y. Li, B. Sixou, and F. Peyrin, "A review of the deep learning methods for medical images super-resolution problems," *Irbm*, vol. 42, pp. 120-133, 2021.
- [15] Y. LeCun, "LeNet-5, convolutional neural networks," URL: <http://yann.lecun.com/exdb/lenet>, vol. 20, p. 14, 2015.
- [16] Y. Luo, L. Zhou, S. Wang, and Z. Wang, "Video satellite imagery super-resolution via convolutional



- [32] Y. Liu, D. Yang, F. Zhang, Q. Xie, and C. Zhang, "Deep recurrent residual channel attention network for single image super-resolution," *The Visual Computer*, pp. 1-16, 2023.
- [33] W. Weng, Y. Zhang, and Z. Xiong, "Boosting event stream super-resolution with a recurrent neural network," in *European Conference on Computer Vision*, 2022, pp. 470-488.
- [34] W. Han, S. Chang, D. Liu, M. Yu, M. Witbrock, and T. S. Huang, "Image super-resolution via dual-state recurrent networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 1654-1663.
- [35] Y. Fu, Z. Liang, and S. You, "Bidirectional 3D quasi-recurrent neural network for hyperspectral image super-resolution," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 2674-2688, 2021.
- [36] M. R. Arefin, V. Michalski, P.-L. St-Charles, A. Kalaitzis, S. Kim, S. E. Kahou, et al., "Multi-image super-resolution for remote sensing using deep recurrent networks," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2020, pp. 206-207.
- [37] J. Kim, J. K. Lee, and K. M. Lee, "Deeply-recursive convolutional network for image super-resolution," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 1637-1645.
- [38] W.-S. Lai, J.-B. Huang, N. Ahuja, and M.-H. Yang, "Fast and accurate image super-resolution with deep laplacian pyramid networks," *IEEE transactions on pattern analysis and machine intelligence*, vol. 41, pp. 2599-2613, 2018.
- [39] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, pp. 1735-1780, 1997.
- [40] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," *IEEE transactions on neural networks and learning systems*, vol. 28, pp. 2222-2232, 2016.
- [41] Y. Chang and B. Luo, "Bidirectional convolutional LSTM neural network for remote sensing image super-resolution," *Remote Sensing*, vol. 11, p. 2333, 2019.
- [42] H. Zhu, M. Guo, H. Li, Q. Wang, and A. Robles-Kelly, "Breaking the spatio-angular trade-off for light field super-resolution via lstm modelling on epipolar plane images," *arXiv preprint arXiv:1902.05672*, 2019.
- [43] C. Chou, J. Park, and E. Chou, "Generating high-resolution climate change projections using super-resolution convolutional LSTM neural networks," in *2021 13th International Conference on Advanced Computational Intelligence (ICACI)*, 2021, pp. 293-298.
- [44] X. Lu, X. Liu, L. Zhang, F. Jia, and Y. Yang, "Hyperspectral image super-resolution based on attention ConvBiLSTM network," *International Journal of Remote Sensing*, vol. 43, pp. 5059-5074, 2022.
- [45] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [46] T. Lu, J. Wang, Y. Zhang, Z. Wang, and J. Jiang, "Satellite image super-resolution via multi-scale residual deep neural network," *Remote Sensing*, vol. 11, p. 1588, 2019.
- [17] K. Umehara, J. Ota, and T. Ishida, "Application of super-resolution convolutional neural network for enhancing image resolution in chest CT," *Journal of digital imaging*, vol. 31, pp. 441-450, 2018.
- [18] M. U. Müller, N. Ekhtiari, R. M. Almeida, and C. Rieke, "Super-resolution of multispectral satellite images using convolutional neural networks," *arXiv preprint arXiv:2002.00580*, 2020.
- [19] M. Taş and B. Yılmaz, "Super-resolution convolutional neural network based pre-processing for automatic polyp detection in colonoscopy images," *Computers & Electrical Engineering*, vol. 90, p. 106959, 2021.
- [20] H. M. Keshk and X.-C. Yin, "Satellite super-resolution images depending on deep learning methods: a comparative study," in *2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*, 2017, pp. 1-7.
- [21] C. Tian, R. Zhuge, Z. Wu, Y. Xu, W. Zuo, C. Chen, et al., "Lightweight image super-resolution with enhanced CNN," *Knowledge-Based Systems*, vol. 205, p. 106235, 2020.
- [22] J. Yamanaka, S. Kuwashima, and T. Kurita, "Fast and accurate image super-resolution by deep CNN with skip connection and network in network," in *Neural Information Processing: 24th International Conference, ICONIP 2017, Guangzhou, China, November 14-18, 2017, Proceedings, Part II 24*, 2017, pp. 217-225.
- [23] C. Dong, C. C. Loy, K. He, and X. Tang, "Learning a deep convolutional network for image super-resolution," in *European conference on computer vision*, 2014, pp. 184-199.
- [24] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, et al., "Generative adversarial nets," *Advances in neural information processing systems*, vol. 27, 2014.
- [25] J. Zhu, C. Tan, J. Yang, G. Yang, and P. Lio', "Arbitrary Scale Super-Resolution for Medical Images," *International journal of neural systems*, vol. 31, p. 2150037, 2021.
- [26] Y. Gu, Z. Zeng, H. Chen, J. Wei, Y. Zhang, B. Chen, et al., "MedSRGAN: medical images super-resolution using generative adversarial networks," *Multimedia Tools and Applications*, vol. 79, pp. 21815-21840, 2020.
- [27] H. Liu, J. Liu, S. Hou, T. Tao, and J. Han, "Perception consistency ultrasound image super-resolution via self-supervised CycleGAN," *Neural Computing and Applications*, pp. 1-11, 2021.
- [28] D. Mahapatra, B. Bozorgtabar, and R. Garnavi, "Image super-resolution using progressive generative adversarial networks for medical image analysis," *Computerized Medical Imaging and Graphics*, vol. 71, pp. 30-39, 2019.
- [29] X. Bing, W. Zhang, L. Zheng, and Y. Zhang, "Medical image super-resolution using improved generative adversarial networks," *IEEE Access*, vol. 7, pp. 145030-145038, 2019.
- [30] X. Yu and F. Porikli, "Ultra-resolving face images by discriminative generative networks," in *European conference on computer vision*, 2016, pp. 318-333.
- [31] L. R. Medsker and L. Jain, "Recurrent neural networks," *Design and Applications*, vol. 5, p. 2, 2001.



- [61] R. Zhang, P. Isola, A. A. Efros, E. Shechtman, and O. Wang, "The unreasonable effectiveness of deep features as a perceptual metric," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 586-595.
- [62] A. Mittal, R. Soundararajan, and A. C. Bovik, "Making a "completely blind" image quality analyzer," *IEEE Signal processing letters*, vol. 20, pp. 209-212, 2012.
- [63] C. Ma, C.-Y. Yang, X. Yang, and M.-H. Yang, "Learning a no-reference quality metric for single-image super-resolution," *Computer Vision and Image Understanding*, vol. 158, pp. 1-16, 2017.
- [64] N. Venkatanath, D. Praneeth, M. C. Bh, S. S. Channappayya, and S. S. Medasani, "Blind image quality evaluation using perception based features," in *2015 twenty first national conference on communications (NCC)*, 2015, pp. 1-6.
- [65] L. Hitachi, "Super-resolution technology to convert video of various resolutions to high-definition," ed.
- [66] Y. Wang, R. Fevig, and R. R. Schultz, "Super-resolution mosaicking of UAV surveillance video," in *2008 15th IEEE International Conference on Image Processing*, 2008, pp. 345-348.
- [67] M. D. Robinson, S. J. Chiu, C. A. Toth, J. A. Izatt, J. Y. Lo, and S. Farsiu, "New applications of super-resolution in medical imaging," in *Super-resolution imaging*, ed: CRC Press, 2017, pp. 383-412.
- [68] R. Willett, I. Jermyn, R. Nowak, and J. Zerubia, "Wavelet-based superresolution in astronomy," ed: Astronomical Society of the Pacific, 2003.
- [69] W. Liu, D. Lin, and X. Tang, "Hallucinating faces: Tensorpatch super-resolution and coupled residue compensation," in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2005, pp. 478-484.
- [70] Z. Yuan, J. Wu, S.-i. Kamata, A. Ahrary, and P. Yan, "Fingerprint image enhancement by super-resolution with early stopping," in *2009 IEEE International Conference on Intelligent Computing and Intelligent Systems*, 2009, pp. 527-531.
- [71] G. Fahmy, "Super-resolution construction of iris images from a visual low resolution face video," in *2007 9th International Symposium on Signal Processing and Its Applications*, 2007, pp. 1-4.
- [47] W. Muhammad, Z. Bhutto, S. Masroor, M. H. Shaikh, J. Shah, and A. Hussain, "IRMIRS: Inception-ResNet-Based Network for MRI Image Super-Resolution," *CMES-Computer Modeling in Engineering & Sciences*, vol. 136, 2023.
- [48] Q. Qin, J. Dou, and Z. Tu, "Deep ResNet based remote sensing image super-resolution reconstruction in discrete wavelet domain," *Pattern Recognition and Image Analysis*, vol. 30, pp. 541-550, 2020.
- [49] D.-W. Jang and R.-H. Park, "Densenet with deep residual channel-attention blocks for single image super resolution," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2019, pp. 0-0.
- [50] S. Bell-Kligler, A. Shocher, and M. Irani, "Blind super-resolution kernel estimation using an internal-gan," *Advances in Neural Information Processing Systems*, vol. 32, 2019.
- [51] E. Agustsson and R. Timofte, "Ntire 2017 challenge on single image super-resolution: Dataset and study," in *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 2017, pp. 126-135.
- [52] J. Cai, H. Zeng, H. Yong, Z. Cao, and L. Zhang, "Toward real-world single image super-resolution: A new benchmark and a new model," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019, pp. 3086-3095.
- [53] P. Wei, Z. Xie, H. Lu, Z. Zhan, Q. Ye, W. Zuo, et al., "Component divide-and-conquer for real-world image super-resolution," in *Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part VIII 16*, 2020, pp. 101-117.
- [54] C. Chen, Z. Xiong, X. Tian, Z.-J. Zha, and F. Wu, "Camera lens super-resolution," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 1652-1660.
- [55] X. Zhang, Q. Chen, R. Ng, and V. Koltun, "Zoom to learn, learn to zoom," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 3762-3770.
- [56] W. Wang, E. Xie, X. Liu, W. Wang, D. Liang, C. Shen, et al., "Scene text image super-resolution in the wild," in *Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part X 16*, 2020, pp. 650-666.
- [57] T. Köhler, M. Bätz, F. Naderi, A. Kaup, A. Maier, and C. Riess, "Toward bridging the simulated-to-real gap: Benchmarking super-resolution on real data," *IEEE transactions on pattern analysis and machine intelligence*, vol. 42, pp. 2944-2959, 2019.
- [58] H. R. V. Joze, I. Zharkov, K. Powell, C. Ringler, L. Liang, A. Roulston, et al., "Imagepairs: Realistic super-resolution dataset via beam splitter camera rig," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2020, pp. 518-519.
- [59] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE transactions on image processing*, vol. 13, pp. 600-612, 2004.
- [60] H. R. Sheikh, A. C. Bovik, and G. De Veciana, "An information fidelity criterion for image quality assessment using natural scene statistics," *IEEE Transactions on image processing*, vol. 14, pp. 2117-2128, 2005.



## بهبود پایداری ریزشبکه ها با استفاده از کنترل کننده مود لغزشی تطبیقی

مهدی متوسل\*

گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران  
 Mehdi\_motevasel@yahoo.com

**چکیده:** امروزه ریزشبکه ها به عنوان بخش مهمی از شبکه های توزیع هوشمند هستند که شامل انواع منابع تولید انرژی تجدیدپذیر بوده و می تواند به دو صورت متصل/منفصل از شبکه اصلی فعالیت کنند. کنترل کننده های ریزشبکه مهمترین نقش را برای عملکرد رضایت بخش خودکار و کنترل ریزشبکه در حین کار بر عهده دارند. کنترل کننده زیرشبکه با تنظیم توان های تولیدی منابع انرژی پراکنده، ضمن تامین انرژی مورد نیاز خود می تواند در هنگام وقوع خطای اتصال کوتاه، کلیدزنی و سایر اغتشاشات وارده باعث افزایش پایداری ریزشبکه شود. در این مقاله به بررسی پایداری ریزشبکه در حالت متصل به شبکه هنگامی که اغتشاش و هارمونیک های اضافه در اثر قطع و وصل لحظه ای یا هنگامی که تغییر وضعیت از حالت جزیره ای به حالت متصل شبکه اعمال می شود، پرداخته شده است. برای این منظور، یک طرح کنترلی مبتنی بر مود لغزشی تطبیقی پیشنهاد گردیده است. همچنین برای نشان دادن مقاومت و کارایی سیستم کنترلی از روش تحلیل پایداری لیاپانوف استفاده شده است. نتایج شبیه سازی نشان می دهد تداخل ایجاد شده در اثر تداخل در اینورتر ریزشبکه و اثر اغتشاش برطرف شده و ردیابی با دقت بالایی به دست آمده است.

**واژه های کلیدی:** ریزشبکه، پایداری، کنترل مود لغزشی تطبیقی

## Improving stability of microgrids using adaptive sliding mode controller

Mehdi Motevasel

Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
 Mehdi\_motevasel@yahoo.com

### Abstract:

Today, microgrids are an important part of smart distribution networks, which include all kinds of renewable energy production sources and can operate either connected or disconnected from the main grid. Microgrid controllers play the most important role for the satisfactory automatic operation and control of the microgrid during operation in grid-connected and islanded mode. By adjusting the production capacities of scattered energy sources, the grid controller can increase the stability of the microgrid in the event of a short circuit error, switching and other disturbances. In this article, the stability of the microgrid in the grid-connected state is investigated when disturbances and additional harmonics are applied as a result of disconnection and connection moment or when the state changes from the island state to the grid-connected state. For this purpose, a control scheme based on adaptive sliding mode has been proposed. Also, to show the resistance and efficiency of the control system, the Lyapunov stability analysis method has been used. The simulation results show that the interference caused by the interference in the microgrid inverter and the disturbance effect have been removed and the tracking has been obtained with high accuracy.

**Keywords:** Microgrid, stability, adaptive sliding mode control

DOI: 00.00000/0000

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۲/۱۲/۲۵

تاریخ پذیرش مقاله: ۱۴۰۲/۰۳/۱۱

تاریخ ارسال مقاله: ۱۴۰۲/۰۲/۰۸

\* نویسنده مسئول؛ نشانی: ایران - شیراز - دانشگاه آزاد اسلامی شیراز - دانشکده مهندسی - گروه مهندسی برق

## ۱- مقدمه

یک ریزشبكة می‌تواند به شبکه سراسری توزیع متصل باشد یا نباشد. در صورتی که این ریزشبكة به خطوط سراسری متصل باشد، ریزشبكة تنها نیاز دارد تا در ساعات اوج<sup>۵</sup> مصرف، در صورت لزوم از شبکه سراسری، انرژی تهیه کند. در سایر ساعات شبانه‌روز، ریزشبكة می‌تواند انرژی تولیدی مازاد خود را به شبکه سراسری بفروشد. در صورتی که ریزشبكة، به خطوط سراسری متصل نباشد، این شبکه نمی‌تواند در ساعات اوج مصرف، انرژی از شبکه خریداری کند؛ در این حالت، مدیریت شبکه از اهمیت بیشتری برخوردار خواهد بود [۴].

نیروگاه‌های موجود در یک ریزشبكة می‌توانند منابع AC یا DC باشند. نیروگاه خورشیدی، برق DC تولید می‌کند در حالی که اغلب نیروگاه‌های فسیلی برق AC تولید می‌کنند. بنابراین به طور کلی، یک ریزشبكة شامل هم منابع AC و هم منابع DC است. تبدیل منابع AC به DC و بالعکس با مبدل‌های موجود در شبکه انجام می‌پذیرد. هم‌چنین، در برخی از ریزشبكة‌ها، منابع ذخیره‌ساز انرژی نیز وجود دارند. وظیفه این منابع، ذخیره انرژی مازاد شبکه در ساعات بی‌باری و تامین انرژی مورد نیاز شبکه در ساعات اوج مصرف است. اکثر منابع ذخیره‌ساز انرژی، از نوع منابع DC هستند [۵].

روش‌های کنترل ریزشبكة‌ها می‌توانند به طور محسوس‌تری سیستم‌های قدرت گذشته متفاوت باشند. این تفاوت بستگی به شکل و همچنین عمق نفوذ واحدهای منابع انرژی توزیع شده، مشخصات بار، کیفیت توان و سهم بودن بازار تجارت برق دارد. در نتیجه، روش‌های کنترلی بدیع باید در ابزارهای جدید تعبیه شوند. این ابزارها به ریزشبكة اجازه می‌دهند تا توان اکتیو و راکتیو را تنظیم نمایند و منابع انرژی تجدیدپذیر را نیز کنترل کند [۹]. در دو حالت اتصال به شبکه و حالت جزیره‌ای، ریزشبكة نقش مهمی را در تنظیم انرژی در بازار تجارت ایفا می‌کند. ریزشبكة‌ها می‌توانند طوری عمل کنند که تمامی مشتری‌ها را با استفاده از تولید محلی خود سرویس‌دهی کنند بدون آنکه انرژی را به شبکه توزیع صادر کنند. این استراتژی مزایایی برای اپراتور سیستم توزیع دارد؛ از جمله اینکه در هنگام پیک درخواست، تراکم شبکه را کاهش می‌دهد. بنابراین ریزشبكة‌ها می‌توانند به طور مستقیم در بازار برق و خرید و فروش توان اکتیو و راکتیو شرکت کنند. برای آدرس‌دهی این نیازها، مدیریت ریزشبكة‌ها باید از یک سری توابع مانند برنامه اقتصادی، بار، وضعیت آب و هوایی، کنترل‌کننده‌های دیجیتال شبکه، امنیت و مدیریت درخواست اطمینان حاصل کنند. با توجه به معماری کنترل، می‌توان سه سطح ساختار را گسترش داد:

- سطح توزیع: این سطح برای دیسپاچینگ در سطح توزیع مورد استفاده است.

تامین برق در شبکه‌های سنتی، توسط نیروگاه‌های بزرگ که به صورت متمرکز در نقاط مشخصی قرار گرفته‌اند، انجام می‌شود. انرژی تولید شده باید توسط شبکه‌های انتقال و توزیع به نقاط مصرف انتقال داده شود. سیستم قدرت فوق دارای اشکالات بسیاری است که از آن جمله می‌توان به کاهش قابلیت اطمینان و دسترس‌پذیری در اثر فرسوده شدن زیرساخت‌های سیستم الکتریکی و تحمیل هزینه‌های زیاد تلفات در انتقال انرژی به نقاط بار اشاره کرد. با رشد مصرف الکتریکی و تقاضا برای کیفیت بالاتر برق مصرفی، صنعت برق به سوی استفاده از فناوری‌های جدید سوق یافته است. از سوی دیگر، روند روبه رشد خصوصی‌سازی، رقابتی شدن بازار برق و تبدیل سرمایه‌گذاران بزرگ به سرمایه‌گذاران کوچک، مدیران صنعت برق را بر این می‌دارد تا بیش از پیش به افزایش توان تولیدی و تجهیزات شبکه با حداکثر بازدهی انرژی و حداقل هزینه بهره‌برداری توجه کنند. یکی از روش‌های بهبود کارایی شبکه توزیع قدرت، استفاده از فناوری تولیدات پراکنده برای تولید برق است. ریزشبكة‌ها، شبکه‌های توزیع فعال ولتاژ پایین و یا ولتاژ متوسطی هستند که از مجموعه‌ای متشکل از بارها، منابع تولید پراکنده و ادوات کنترلی تشکیل شده است. طبق تعریف، ظرفیت یک ریزشبكة می‌تواند بین چند ده کیلووات تا چند ده مگاوات باشد. [۱]

با توجه به افزایش نفوذ واحدهای تولید پراکنده<sup>۱</sup> (DG) در شبکه قدرت، منابع انرژی تجدیدپذیر<sup>۲</sup> (RES) شامل توربین‌های بادی، پیل سوختی، سیستم‌های فتوولتاییک و انرژی نیز به طور گسترده در دهه‌های اخیر مورد بهره‌برداری قرار گرفته‌اند [۱۰ و ۱۱]. واحدهای DG نقش مهمی را در کاهش آلودگی، کاهش تلفات توان انتقالی و بهبود کیفیت توان بازی می‌کنند که این موضوع در شبکه‌های با مقیاس بزرگ از اهمیت بیشتری برخوردار است. علاوه بر این مزایا، استفاده از واحدهای DG ممکن است در برخی مسائل مانند شارش توان معکوس، انحراف ولتاژ و نوسانات ولتاژ، چالش برانگیز باشد. زمانی که تعداد زیادی واحد DG در مجاور یکدیگر جمع شوند، می‌توانند یک ریزشبكة<sup>۳</sup> (MG) را تشکیل دهند. این ریزشبكة‌ها می‌توانند مسائلی که ناشی از نفوذ زیاد DGها در شبکه می‌باشند را حل کنند [۲].

سیستم‌های فتوولتاییک و ذخیره‌کننده‌ها<sup>۴</sup> (ESS) توسط مبدل‌های AC-DC-AC به شبکه AC متصل می‌گردند. توربین‌های بادی نیز به وسیله یک مبدل AC-DC-AC به شین‌های AC متصل می‌گردند. در حالت بهره‌برداری جزیره‌ای، RESها به طور گسترده بارهای محلی را تامین می‌نمایند. در حالت متصل به شبکه، ریزشبكة به شین اتصال مشترک (PCC<sup>۶</sup>) وصل می‌شود. این شین، شارش توان و پخش بار بین ریزشبكة و شبکه بالادست را کنترل می‌نماید. [۳].

<sup>۵</sup> Alternative current

<sup>۶</sup> Point of Common Coupling

<sup>۷</sup> Peak Loads

<sup>۱</sup> Distributed Generation

<sup>۲</sup> Renewable Energy Sources

<sup>۳</sup> Micro Grid

<sup>۴</sup> Energy Storage System



- سطح ریزش‌بکه‌ها: کنترل‌کننده مرکزی شبکه بخش ارتباطی بین ریزش‌بکه و شبکه اصلی است.

- سطح واحدها: کنترل‌کننده‌های محلی؛ در واقع این سطح برای منابع توزیع انرژی و بارهای قابل کنترل توسعه یافته است و می‌توان از آن برای تنظیم ولتاژ و فرکانس استفاده نمود [۶].

## ۲- نحوه کنترل ریزش‌بکه‌ها

در سیستم‌های کنترل، کنترل حالت جزیره ای (SMC) یک روش کنترلی غیرخطی است که با استفاده از یک سیگنال کنترل ناپیوسته (یا دقیق‌تر، یک سیگنال کنترل تنظیم‌شده دارای ارزش) دینامیک سیستم غیرخطی را تغییر می‌دهد. در طول مقطعی از رفتار عادی سیستم، قانون کنترل بازخورد دولت تابعی از زمان مداوم نیست. در عوض، می‌تواند براساس موقعیت فعلی در فضای دولت، مداوماً از یک ساختار به ساختار دیگر تغییر کند. از این رو، کنترل حالت جزیره‌ای یک روش کنترل ساختار متغیر است. ساختارهای کنترل چندگانه به گونه‌ای طراحی شده‌اند که مسیرها همیشه به سمت یک منطقه مجاور با ساختار کنترل متفاوت حرکت می‌کنند، بنابراین مسیر نهایی به طور کامل در یک ساختار کنترل وجود نخواهد داشت. در عوض، در امتداد مرزهای ساختارهای کنترل کشیده می‌شود. حرکت سیستم به هنگام کشیدن در امتداد این مرزها، حالت جزیره ای نامیده می‌شود و مکان هندسی متشکل از مرزها، سطح جزیره‌ای (هایپر) نام دارد. در چارچوب نظریه کنترل مدرن، هر سیستم ساختار متغیر -مانند یک سیستم تحت کنترل مود لغزشی- ممکن است به عنوان یک مورد خاص از یک سیستم دینامیکی ترکیبی مورد بررسی قرار گیرد، زیرا این سیستم نه تنها از طریق یک فضای حالت مداوم جریان می‌یابد، بلکه از طریق حالت‌های کنترل گسسته مختلف نیز حرکت می‌کند [۷].


کنترل حالت جزیره‌ای با استفاده از سود تقریباً نامتناهی، مسیرهای یک سیستم پویا را به حرکت در زیر فضای جزیره‌ای محدود می‌کند. مسیرهای این حالت جزیره‌ای مرتب شده دارای خواص مطلوب هستند (به عنوان مثال، سیستم به طور طبیعی در طول آن حرکت می‌کند تا زمانی که در تعادل مورد نظر استراحت کند). قدرت اصلی کنترل حالت جزیره‌ای استحکام آن است. از آنجا که کنترل می‌تواند به سادگی تعویض بین دو حالت باشد (به عنوان مثال، "خاموش" / "خاموش" یا "رو به جلو" / "معکوس")، لازم نیست دقیق باشد و نسبت به تغییرات پارامتری که وارد آن می‌شود حساس نیست. همچنین کانال کنترل می‌تواند حالت جزیره‌ای را در زمان محدود به دست آورد. در شرایط خاص، کنترل بهینه نیاز به استفاده از روش بنگ-بنگ دارد. از این رو، کنترل حالت جزیره‌ای کنترل‌کننده بهینه را برای مجموعه گسترده‌ای از سیستم‌های پویا توصیف می‌کند. یکی از کاربردهای کنترل‌کننده حالت جزیره‌ای، کنترل درایوهای برقی است که با تعویض مبدل‌های برق کار می‌کنند. به دلیل عملکرد

ناپیوسته مبدل‌ها، یک کنترل‌کننده حالت جزیره‌ای ناپیوسته، یک انتخاب عملی نسبت به کنترل‌کننده‌های مداوم است. نیاز به استفاده از مدولاسیون عرض پالس یا تکنیک مشابه برای اعمال سیگنال مداوم بر روی خروجی است که فقط می‌تواند حالت‌های گسسته‌ای داشته باشد. کنترل حالت جزیره‌ای کاربردهای زیادی در رباتیک دارد. به طور خاص، این الگوریتم کنترل برای ردیابی کشتی‌های سطح بدون سرنشین در دریا‌های شبیه‌سازی شده با درجه موفقیت بالا استفاده شده است [۸].


کنترل حالت جزیره‌ای باید با دقت بیشتری نسبت به سایر اشکال کنترل غیرخطی که دارای کنترلی معتدل‌تر هستند، اعمال شود. به ویژه، به دلیل اینکه محرک‌ها دارای تاخیرها و سایر نواقص هستند، عملکرد کنترل حالت جزیره‌ای می‌تواند منجر به اتلاف انرژی و تحریک پویایی‌های اصلاح نشده شود. روش‌های طراحی مداوم کنترل به این صورت نیستند و مستعد ابتلا به این مشکلات بوده و می‌توان از آن به جای کنترل‌کننده‌های حالت جزیره ای استفاده کرد.

در واقع، این شبکه جزیره‌ای است که به صورت تعمدی در یک مجموعه تأسیسات یا در یک سیستم توزیع الکتریکی شکل می‌گیرد و شامل دست کم یک منبع انرژی و بارهای مربوطه می‌باشد. در واقع، شبکه جزیره‌ای را یک سیستم قدرت کوچک می‌دانند که به طور معمول در مقیاس چندین مگاوات یا کمتر که دارای سه مشخصه اصلی است: تولیدات پراکنده، مراکز بار مستقل و قابلیت بهره‌برداری متصل یا منفصل از شبکه الکتریکی بزرگتر. بخش‌های اصلی یک شبکه جزیره‌ای شامل تولید پراکنده، ذخیره پراکنده، کلیدهای اتصال و سیستم‌های کنترل باشد. کلید اتصال، نقطه ارتباط بین اجزای جزیره‌ای و مابقی سیستم توزیع است. تکنولوژی‌های مختلفی برای کارکرد مناسب کلیدزنی مورد نیاز است که شامل اندازه‌گیری، رله‌های حفاظتی، تجهیزات مخابراتی و غیره می‌باشد. هنگامی که کلید باز می‌شود، منابع تولید توان در شبکه جزیره‌ای باید بتوانند بار آن را با فرکانس مناسب و حفظ سطح ولتاژ تغذیه نمایند. بسته به تکنولوژی کلید ممکن است قطع‌های لحظه‌ای در طی انتقال از مود متصل به شبکه به مود جزیره رخ دهد که در این صورت لازم است منابع تولید توان الکتریکی پس از باز شدن کلید، راه‌اندازی مجدد شوند. طراحی اولیه شبکه جزیره‌ای باید به نحوی باشد که در هنگام بهره‌برداری در مود مستقل از شبکه، تعادل میان تولید و مصرف توان برقرار باشد. تحلیل پخش بار نیز برای حالت‌های مختلف طراحی باید انجام پذیرد تا از حفظ تنظیم ولتاژ مناسب و توانایی منابع تولید توان برای مقابله با جریان‌های هجومی ناشی از بارهای بزرگ، اطمینان حاصل گردد. در حالت جزیره، مدیریت تولید و بار امری بسیار مهم است. حاشیه رزرو کافی که تابعی از ضریب بار، مقدار بار، شکل بار، قابلیت اطمینان مورد نیاز و ضریب بار، مقدار بار، شکل بار، قابلیت اطمینان مورد نیاز بار و دسترس‌پذیری منابع تولید توان است و نیز نمایش مناسب برای بهره‌برداری و تشخیص وضعیت شبکه جزیره‌ای باید وجود داشته باشد.






شکل (۱): مدل ریزشبهه



شکل (۲): مدل پنل فتوولتائیک



شکل (۳): شماتیک یک واحد فتوولتائیک سه فاز مبتنی بر اینورتر

### ۳-۲-۳ مدل اینورتر سه فاز

شکل (۳) یک واحد فتوولتائیک سه فاز مبتنی بر اینورتر با یک فیلتر LC را نشان می‌دهد. ساختار اینورتر منیع ولتاژ شامل سه مبدل H-bridge تک فاز با به کارگیری کلیدهای IGBT می‌باشد که خروجی هر H-bridge به ترانسفورماتورهای تک فاز متصل شده و مقاومت  $R_f$  نشان‌دهنده تلفات ترانسفورماتور و کلیدزنی، اندوکتانس  $L_f$  نشان‌دهنده راکتانس نشتی ترانسفورماتور می‌باشد. همچنین خازن فیلتر  $C_f$  برای حذف هارمونیک‌های کلیدزنی<sup>۱</sup> به خروجی ترانسفورماتورها متصل شده است.

با در نظر گرفتن پارامترها در شرایط نامی و با به کارگیری تبدیل شناخته شده پارک معادلات دینامیکی ولتاژ و جریان در قاب مرجع dq مطابق زیر خواهد بود:

$$V_{L_f} = L_f \frac{dI_{f,dq}}{dt} = V_{i,dq} - R_f I_{f,dq} - V_{f,dq} - j \omega_0 L_f I_{f,dq} \quad (3)$$

$$I_{C_f} = C_f \frac{dV_{f,dq}}{dt} = I_{f,dq} - I_{o,dq} - \omega_0 C_f V_{f,dq} \quad (4)$$

فرض شود  $a = \frac{1}{L_f}$  و  $b = R_f$  و  $c = \frac{1}{C_f}$  مقادیر نامی پارامترها

[۹]. سیستم کنترل جزیره‌ای به منظور کارکرد مطمئن سیستم در مدهای متصل و متصل به شبکه طراحی می‌شود. این سیستم می‌تواند بر پایه یک کنترل کننده مرکزی بوده یا به صورت بخش‌های کنترل کننده در هر ژنراتور تعبیه شود. استفاده از سیستم‌های چندکاره نیز برای کنترل شبکه‌های جزیره‌ای پیشنهاد شده است. هنگامی که اتصال از شبکه قطع می‌شود، سیستم کنترل باید فرکانس و ولتاژ را کنترل کرده و اختلاف توان حقیقی و راکتیو لحظه‌ای بین تولید و مصرف را تأمین نماید. کنترل ولتاژ و فرکانس در سیستم‌های هیبرید باد-دیزل توسط ژنراتور دیزلی انجام می‌گردد. در سیستم هیبریدی بادی-آبی این وظیفه بر عهده ژنراتور آبی خواهد بود [۹ و ۱۰].

### ۳-۲-۳ مدل‌سازی ریزشبهه

در شکل (۱) نمودار کلی ریزشبهه نشان داده شده است. تولید پراکنده در اینجا توسط یک منبع فتوولتائیک که توسط مبدل الکترونیک قدرت و یک ترانسفورماتور افزایشدهنده و شبکه سراسری و بار محلی متصل شده، نشان داده شده است. سیستم باید بتواند در هر دو حالت متصل به شبکه و جدا از شبکه بار را تغذیه کند. شبکه مورد بررسی در حالت متصل به شبکه می‌باشد. در این شرایط مبدل میانی به عنوان یک کنترل کننده جریان منبع ولتاژ (کنترل جریان  $d,q$ ) برای تولید پراکنده عمل می‌کند، در این مقاله هنگامی که کلید بریکر باز شود در حالت جزیره‌ای و هنگامی که کلید بسته شود حالت متصل به شبکه اتفاق می‌افتد. در لحظه باز و بسته شدن یا قطع و وصل مجدد ریزشبهه به شبکه بالادست، یک اغتشاش به ریزشبهه اعمال شده و بسته به مقدار و جهت توان مبادلاتی ریزشبهه با شبکه بالادست ولتاژ و فرکانس شبکه افزایش یا کاهش یابد و سیستم به سمت ناپایداری می‌رود که هدف بهبود پایداری سیستم است.

### ۳-۱-۳ مدل سیستم فتوولتائیک

مدلی که در این مقاله به کار گرفته شده، مدل تک‌دیودی پنل فتوولتائیک است (شکل (۲)). این مدل از پنل فتوولتائیک عموماً در مقالات به کار برده می‌شود، چرا که علاوه بر قابلیت عملیاتی بودن، دارای مصالحه‌ای بین دقت و سادگی می‌باشد [۱۰]. برای یک ولتاژ داده شده  $V$ ، جریان سلول  $I$  به وسیله معادله شناخته شده زیر تقریب زده می‌شود:


$$I = I_L - I_s \left( \exp \left[ \frac{V + R_s I}{V_T} \right] - 1 \right) - \frac{V + R_s I}{R_{sh}} \quad (1)$$

که در آن جریان فتون  $I_L$ ، جریان اشباع معکوس  $I_s$ ، ولتاژ ترمینال  $V_T$ ، مقاومت سری  $R_s$  و مقاومت شنت  $R_{sh}$  می‌باشد.

1. Switching



شکل (۴): بلوک دیاگرام طرح کنترل



شکل (۵): بلوک دیاگرام در حوزه لاپلاس حالت متصل به شبکه

#### ۴-۱- معادلات سیستم در حالت اتصال ریزشبه

شکل (۵) معادلات هر فاز اینورتر متصل به شبکه در حوزه لاپلاس را نشان می‌دهد. مدل سازی ریاضی عملکرد یک ریزشبه متصل به شبکه، نیاز به در نظر گرفتن قیود هر یک از تجهیزات داخل ریز شبکه دارد و این قیود بایستی تا حد ممکن بهینه انتخاب شوند که مساله بهینه سازی نهایی، ساده و کاربردی باشد. با فرض اینکه همه ابزارآلات سوئیچینگ، ایده آل و بدون تأخیر بوده و ترانسفورمر نیز ایده آل است و همچنین زاویه جابه جایی از هر فاز استفاده، قابل صرف نظر کردن است، دینامیک معادلات هر فاز از سیستم اینورتر متصل به شبکه به شکل زیر نمایش داده می‌شود:

$$\frac{di_o}{dt} = \frac{1}{L_f} (K_{PWM} u_{in} - u_s - i_o R_f - d_1) \quad (7)$$

در (۷)،  $K_{PWM}$  پارامتر معادل مدار مدولار اینورتر است، سیگنال ورودی کنترل  $u_{in}$ ، ولتاژ خروجی برای کنترل اینورتر  $K_{PWM} u_{in}$  را نشان می‌دهد. ولتاژ شبکه  $u_s$  و اغتشاش ولتاژ شبکه  $d_1$  را نشان می‌دهد. معادلات بالا به شکل زیر بازنویسی می‌شوند.

$$\frac{di_o}{dt} = \frac{K_{PWM}}{L_f} u_{in} - \frac{1}{L_f} u_s - \frac{R_f}{L_f} i_o - \frac{1}{L_f} d_1 \quad (8)$$

#### ۴-۲- طراحی کنترل کننده مد لغزشی تطبیقی

هدف اصلی طراحی کنترل کننده داخلی برای این سیستم، افزایش مقاومت سیستم در دفع اغتشاش ولتاژ و رسیدن به ردیابی مناسب برای جریان سیستم است. معادلات جریان خروجی هر فاز سیستم در زیر بازنویسی شده است.

$$\begin{aligned} \dot{x}_g(t) &= a_p x_g(t) + b_p u(t) + c_p z(t) + m(t) \\ x_g(t) &= i_o, u(t) = u_{in}(t), z(t) = u_s \\ a_p &= -\frac{R_f}{L_f}, b_p = \frac{K_{PWM}}{L_f}, c_p = -\frac{1}{L_f} \end{aligned} \quad (9)$$

در این معادلات مجموع اغتشاش و عدم قطعیت‌های دیگر سیستم  $m(t)$  است که داریم  $|m(t)| < \tau$  که در آن  $\tau$  یک عدد ثابت مثبت است.

برای بهبود کنترل کننده و کاهش نوسانات فرکانس بالا، روش سطح لغزشی برخلاف مقالات دیگر از مشتق سیگنال کنترل به عنوان

هستند. اگر پارامترهای سیستم از مقدار نامی شان انحراف یابند، آنگاه روابط دینامیکی به صورت زیر اصلاح می‌گردد:

$$\begin{aligned} \frac{dI_{f,dq}}{dt} &= a(V_{i,dq} - bI_{f,dq} - V_{f,dq}) - j\omega_0 I_{f,dq} + \zeta_{i,dq} \\ \frac{dV_{f,dq}}{dt} &= c(I_{f,dq} - I_{o,dq}) - j\omega_0 V_{f,dq} + \zeta_{v,dq} \end{aligned} \quad (5)$$


که  $\zeta_{i,dq}$  و  $\zeta_{v,dq}$  بردارهای عدم قطعیت تجمیع شده هستند و به صورت زیر بیان می‌شوند:

$$\zeta_{v,dq} = \Delta c (I_{f,dq} - I_{o,dq}) + \delta_{v,dq} \quad (6)$$

که  $\Delta$  نشان دهنده اختلاف بین مقادیر نامی و ترم های  $\delta_{i,dq}$  و  $\delta_{v,dq}$  می‌باشد و برای محاسبه اغتشاشات دینامیکی سیستم و عدم قطعیت‌های مدل نشده در روابط (۵) و (۶) اضافه شده است. این ترم‌های نامعین<sup>۱</sup> در طی طراحی کنترل کننده غیرخطی از طریق تکنیک برآورد تطبیقی<sup>۲</sup> تخمین زده شده‌اند. به کارگیری این ترم تطبیقی، سیستم را در خطاهای مدل سازی و اندازه گیری قوی تر می‌سازد.

#### ۴- سیستم کنترلی پیشنهادی

در این مقاله، یک سیستم کنترل کننده مقاوم برای سیستم اینورتر ارائه می‌شود. سیستم ریزشبه حالت متصل به شبکه از دو اینورتر با فیلتر، منبع ولتاژ و بار و یک شبکه مشترک بین آن‌ها تشکیل شده است. برای کنترل جریان و ولتاژ سه فاز، اینورتر از روش کنترل مود لغزشی که شامل خطا و تغییرات خطای ردیابی است، استفاده می‌کند. به دلیل سوئیچینگ‌های اینورترهای قدرت، این تجهیزات با کنترل کننده‌های مود لغزشی سازگار می‌باشند. کنترل کننده لغزشی یکی از روش‌های طراحی کنترل مقاوم است که امکان دستیابی به عملکرد مطلوب سیستم را با وجود پارامترهای غیردقیق و تخمین مرتبه پایین تر سیستم در مدل فراهم می‌کند. کنترل لغزشی در واقع مصالحه‌ای بین مدل سازی و عملکرد مناسب با طراحی غیردقیق است. موضوع اصلی کنترل مبدل‌های قدرت، تعریف یک سطح سوئیچینگ مناسب جهت دنبال کردن سیگنال مرجع است. سطح لغزش که بر اساس خطا، انتگرال خطا و تغییرات (شیب) خطا تعریف می‌شود. در این روش قانون کنترل طوری تنظیم می‌شود که در حضور اغتشاش و تداخل، سطح لغزش از یک حالت اولیه غیرصفری در زمان مشخص و کوتاهی به صفر برسد. همچنین برای بهبود سیگنال کنترل و پرهیز از استفاده از دامنه بزرگ برای سیگنال کنترل و تخمین کران بالای اغتشاش و عدم قطعیت، از کنترل تطبیقی استفاده می‌شود؛ و به کمک معیار پایداری لیاپانوف پایداری و مقاومت سیستم تحلیل می‌شود.



<sup>2</sup>. Adaptive Estimation

<sup>1</sup>. Uncertain Terms






ریزشبهه در نظر گرفته شده است. ولتاژهای DC تولیدی توسط این پنل‌های فتوولتائیک به اینورترهای سه فاز وارد می‌شوند که ولتاژ خروجی هر یک از این پنل‌ها مشابه با یکدیگر هستند. اینورترهای سه فاز با رویکرد کنترلی، ولتاژهای DC دریافتی را به ولتاژهای سه فاز تبدیل کرده و به شبکه قدرت تحویل می‌دهند. در این رویکرد با اعمال یک اغتشاش متغیر با زمان که تابعی از ولتاژهای خروجی اینورتر است، درصد بررسی صحت عملکرد کنترل کننده مود لغزشی در از بین بردن این خطا و همگرایی آن به مقدار صفر هستیم. همچنین در این شرایط می‌باید جریان‌های خروجی اینورتر به خوبی جریان‌های مرجع را دنبال کنند و پایداری ولتاژ و جریان به دست آید.

در این شبیه‌سازی پنل‌های فتوولتائیک توسط دو اینورتر موازی به بار وصل شده و از طرفی توسط یک بریکر به شبکه اصلی متصل می‌شوند. بریکر در زمان مشخصی ریزشبهه را به شبکه اصلی متصل کرده و بعد از چند سیکل آن را جدا می‌سازد. در این حالت کنترل ولتاژ اینورتر با استفاده از کنترل کننده مود لغزشی با اعمال یک اغتشاش به شبکه که تابعی از جریان اینورتر می‌باشد مد نظر است. هدف نهایی بررسی عملکرد کنترل کننده مود لغزشی به گونه ای است که شکل موج ولتاژ خروجی اینورتر از قابلیت خوبی در دنبال کردن شکل موج ولتاژ سه فاز مرجع برخوردار باشد. در شبیه‌سازی‌های صورت گرفته بریکر در سیکل چهارم شبیه‌سازی ریز شبکه را به شبکه اصلی متصل می‌سازد و در سیکل دهم آن را جدا می‌سازد. همچنین در شکل (۷) نمودار سطح لغزش هر فاز از جریان اینورتر آورده شده است. سطوح لغزش برای هر دو اینورتر کاملاً یکسان می‌باشد

در شبیه‌سازی‌های صورت گرفته، بریکر در زمان ۴/۶۰ از شبیه‌سازی ریزشبهه را به شبکه اصلی متصل می‌سازد و در زمان ۱۰/۶۰ آن را جدا می‌سازد. هدف اساسی از به کارگیری کنترل کننده مود لغزشی این است که جریان اینورتر سه فاز بتواند با حضور اغتشاش، جریان مرجع را دنبال کرده و منجر به همگرایی خطا و تغییرات آن گردد. شکل (۸) نمودارهای جریان سه فاز مرجع، جریان سه فاز خروجی اینورتر و اختلاف جریان حاصل از این دو جریان را نشان می‌دهد.



شکل (۶): ریزشبهه در حالت اتصال به شبکه

کنترل کننده استفاده می‌شود و در نهایت سیگنال کنترل با انتگرال-گیری به دست می‌آید. خطای ردیابی جریان به شکل  $e_g = i_o - i_r$  تعریف می‌شود و سطح لغزش به صورت زیر در نظر گرفته می‌شود:

$$s_g = k_1 \int e_g(t) + k_2 e_g(t) + \dot{e}_g(t)$$

$$\dot{s}_g(t) = k_1 e_g(t) + k_2 \dot{e}_g(t) + \ddot{e}_g(t)$$

$$\ddot{s}_g(t) = k_1 \dot{e}_g(t) + \ddot{e}_g(t) + k_2 \left( a_p \dot{x}_g(t) + b_p \dot{u}(t) + c_p \dot{z}(t) + \dot{m}(t) - \dot{x}_r \right)$$

$$x_r = i_r$$

که جریان خروجی  $i_o$  و جریان مرجع  $i_r$  است و ضرایب  $k_1$  و  $k_2$  مثبت و غیرصفر هستند و  $\dot{m}(t)$  کران دار است.

قانون کنترل شامل سه قسمت است: کنترل کننده هم‌ارز مدل  $(u_{gtr})$  که از روی مشتق سطح لغزش به دست می‌آید، کنترل کننده سوئیچینگ و قانون کنترل تطبیقی. کنترل کننده هم‌ارز مدل براساس قسمت‌های مشخص و معلوم مدل اینورتر به دست می‌آید، کنترل کننده سوئیچینگ  $(u_{gsw})$  برای تضمین پایداری در حضور عدم قطعیت و اغتشاش نامعلوم که کنترل کننده معادل مدل نمی‌تواند جبران کند، استفاده می‌شود. از کنترل کننده تطبیقی برای رویت کران بالای اغتشاش و کاهش اثر نوسانات فرکانس بالای کنترل کننده سوئیچینگ استفاده می‌شود. با در نظر گرفتن معادلات سطح لغزش قانون کنترل در حالت متصل به شبکه به شکل زیر در می‌آید:

$$u = u_{gsw} + u_{gtr}$$

$$u_{gtr} = - \left( \frac{1}{b_p} \right) \left( c_p u_s + (a_p + k_2) e_g + k_1 \int e_g + a_p i_r - \dot{i}_r \right)$$

$$u_{gsw} = - \left( \frac{1}{b_p} \right) \int \hat{\tau}(t) \operatorname{sgn}(s_g(t)) dt$$

$$\hat{\tau}(t) = |s_g(t)| / \lambda_g$$

برای اثبات پایداری تابع لیاپانوف زیر در نظر گرفته می‌شود:

$$V_g(t) = \frac{1}{2} s_g^2(t) + \frac{\lambda_g}{2} \tilde{\tau}^2(t)$$

که در آن  $\tilde{\tau} = \tau - \hat{\tau}$  خطای تخمین قانون کنترل تطبیقی است. با محاسبه مشتق تابع لیاپانوف و جای‌گذاری سطح لغزش و معادلات اینورتر داریم:

$$\dot{V}_g(t) = s_g(t) \cdot (b_p \dot{u}_{gsw} + \dot{m}(t)) + \lambda_g (\tau - \hat{\tau}) \dot{\tilde{\tau}}(t)$$


$$= s_g(t) \cdot (\hat{\tau}(t) \operatorname{sgn}(s_g(t)) + \dot{m}(t)) - \lambda_g (\tau - \hat{\tau}) \cdot |s_g(t)| / \lambda_g$$

$$= s_g(t) \cdot (m(t)) - \tau \cdot |s_g(t)| \leq |s_g(t)| \cdot (|m(t)| - \tau) \leq 0$$

## ۵- شبیه‌سازی ریزشبهه

در شکل (۶) مدل شبیه‌سازی آورده شده است دو منبع تولید توان تحت قالب پنل‌های فتوولتائیک به عنوان منابع تولید پراکنده در این






شکل (۱۱): توان‌های اکتیو و راکتیو اینورتر

شکل (۱۰) ولتاژهای سه فاز خروجی اینورتر اول و دوم را نشان می‌دهد. همان‌طور که مشاهده می‌شود این دو ولتاژ با توجه به مشابهت مداری کاملاً یکسان هستند. در لحظه  $0/067$  که بریکر ریزش‌بکه را به شبکه اصلی وصل می‌کند افت ولتاژ بسیار زیادی خواهیم داشت که در زمان  $0/17$  با جداسازی مجدد ریزش‌بکه، ولتاژ به مقدار پیشین خود باز می‌گردد. شکل (۱۱) نشان‌دهنده مقادیر RMS توان‌های اکتیو و راکتیو اینورتر می‌باشد. همان‌طور که دیده می‌شود توان راکتیو به خوبی کنترل شده و در مقدار صفر باقی می‌ماند.


با توجه به نتایج به‌دست آمده می‌توان بیان داشت کنترل‌کننده، عملکرد کاملاً مناسبی در ایجاد پایداری سیستم دارد. با وجود اغتشاش ولتاژ اعمال شده به مدار، جریان‌های خروجی اینورتر به خوبی جریان مرجع را دنبال می‌کنند و خطای حاصل از این دو جریان نیز به مقدار صفر همگرا می‌گردد. ولتاژ خروجی اینورتر نیز از پایداری کامل برخوردار بوده است. با توجه به این امر می‌توان بیان داشت کنترل‌کننده پیشنهادی از مقاومت خوبی در برابر اغتشاشات موجود در ریز شبکه برخوردار است.

## ۶- نتیجه‌گیری


در این مقاله به بررسی پایداری ریزش‌بکه در حالت متصل به شبکه هنگامی که اغتشاش و هارمونیک‌های اضافه در اثر لحظه قطع و وصل یا هنگامی تغییر وضعیت از حالت جزیره‌ای به حالت متصل شبکه اعمال می‌شود، پرداخته شده است. طرح کنترل‌کننده مد لغزشی تطبیقی برای اینورتر سه‌فاز نشان داد که اغتشاش گذار و هارمونیک‌های اضافی به شکل مؤثری توسط روش ارائه‌شده از بین رفته و سیستم سریعاً به حالت پایدار می‌رسد. برای بهبود روش کنترل مد لغزشی و افزایش مقاومت سیستم در برابر اغتشاش و عدم قطعیت‌های مدل، از کنترل تطبیقی استفاده شده است که میزان کران بالای اغتشاش را برای جبران در روش کنترل مد لغزشی تخمین می‌زند. همچنین برای نشان دادن کارایی و اعتبار، از روش تحلیل پایداری لیاپانوف برای نشان دادن تضمین پایداری ردیابی سیستم و مقاومت آن و همچنین تخمین پارامترهای تطبیقی استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد تداخل ایجاد شده در اثر تداخل در اینورتر ریزش‌بکه و اثر اغتشاش برطرف شده و ردیابی با دقت بالایی به‌دست آمده است.




شکل (۷): سطح لغزش



شکل (۸): جریان‌های مرجع، جریان اینورتر اول و جریان خطا



شکل (۹): مقایسه جریان‌های مرجع و جریان‌های اینورتر



شکل (۱۰): ولتاژهای سه فاز خروجی اینورترها

## ۷- مراجع

- [1] Rey J.M, Jiménez-Vargas I, Vergara P.P, Osma-Pinto G, and Solano J, "Sizing of an autonomous microgrid considering droop control," *International Journal of Electrical Power & Energy Systems*, vol. 136, 2022 .
- [2] Shafiee-Rad M, Sadabadi M. S, Shafiee Q, and Reza Jahed-Motlagh M, "Modeling and robust structural control design for hybrid AC/DC microgrids with general topology," *International Journal of Electrical Power & Energy Systems*, vol. 139, no. 4, Jul. 2022.
- [3] Chaspierre G, Panciatici P, and Van Cutsem T, "Control of a battery energy storage system to compensate for ADN equivalents inaccuracies," *Electric Power Systems Research*, vol. 213, no. 6, Dec. 2022.
- [4] Lin F.J, Tan K.-H, , and Tseng T.-Y, "Development of intelligent controlled microgrid for power sharing and load shedding," *IEEE Transactions on Power Electronics*, vol. 37, no. 7, pp. 7928–7940, 2022.
- [5] Zhang M, Xu Q, Zhang C, Nordstrom L, and Blaabjerg F. "Decentralized coordination and stabilization of hybrid energy storage systems in DC microgrids," *IEEE Transactions on Smart Grid*, vol. 13, no. 3, pp. 1751–1761, May 2022.
- [6] George A, Ravindran A, Mendieta M, and Tabkhi H, "Mez: an adaptive messaging system for latency-sensitive multi-camera machine vision at the IoT edge," *IEEE Access*, vol. 9, pp. 21457–21473, 2021.
- [7] Huang P, Vorobev P, M. Hosan Vi, Kirtley J. L., and Turitsyn K, "Plug-and-Play Compliant Control for Inverter-Based Microgrids," *IEEE Trans. On Power Sys.*, vol. 34, no. 4, pp. 2901-2913, 2019.
- [8] Nandanoori S. P, Kundu S, Du W, Tuffner F. K., and Schneider K. P, "Distributed Small-Signal Stability Conditions for InverterBased Unbalanced Microgrids," *IEEE Trans. On Power Sys.*, vol. 35, no. 5, pp. 3981-3990, 2020.
- [9] Sharma R. K, Mishra S and Pullaguram D, "A Robust H $\infty$  Multivariable Stabilizer Design for Droop Based Autonomous AC Microgrid," *IEEE Trans. On Power Sys.*, vol. 35, no. 6, pp. 4369-4382, 2020.
- [10] Tenti P, Caldognetto T, "Master/Slave Power-Based Control of Low-Voltage Microgrids," *Advanced Control Methods and Renewable Energy System Integration*, pp. 101-135, 2018.





## Journal of Circuits, Data and Systems Analysis (JCDSA)

Volume 1, Issue 1, Spring 2023

### Papers List

<u>Number</u>	<u>Paper title/Authors</u>	<u>Page</u>
1	Optimal Classification of Brain Tumors in MRI Images Using Deep Learning Techniques Zohreh Arabi, Omid Mahdiyar, Mehdi Taghizadeh*	1
2	Infant Brain Image Segmentation using the Convolutional Neural Networks Iran Sarafraz, Hamed Agahi*, Azar Mahmoodzadeh	16
3	Copy-Move Forgery Detection Techniques based on Traditional Methods in Digital Images Maryam Attaie Gahfarkhi, Azar Mahmoodzadeh*	26
4	Well-Being Model of Power System with Photovoltaic Unit Ayub Alipour, Amir Ghaedi*, Hamid Keyvani	38
5	Deep Learning Algorithms in Super-Resolution Images Bahar Ghaderi, Hamid Azad*	47
6	Improving stability of microgrids using adaptive sliding mode controller Mehdi Motevasel	57



## Journal of Circuits, Data and Systems Analysis (JCDSA) Editorial Board

<b>Director-in-Charge</b>	Hamed Agahi	Islamic Azad University, Shiraz Branch, Shiraz, Iran
<b>Editor-in-Chief</b>	Taher Niknam	Shiraz University of Technology, Shiraz, Iran
<b>Internal Manager</b>	Zahra Maghsoodzadeh	Islamic Azad University, Shiraz Branch, Shiraz, Iran
<b><u>Editorial Board</u></b>		
<i>Professor</i>	Taher Niknam	Shiraz University of Technology, Shiraz, Iran
<i>Professor</i>	Rahim Ghayour	Shiraz University, Shiraz, Iran
<i>Professor</i>	Habibollah Abiri	Shiraz University, Shiraz, Iran
<i>Professor</i>	Hamid Khaloozadeh	K.N.Toosi University of Technology, Tehran, Iran
<i>Professor</i>	Asghar Keshtkar	Imam Khomeini International University, Qazvin, Iran
<i>Professor</i>	Mohammad Bagher Menhaj	Amirkabir University of Technology, Tehran, Iran
<i>Professor</i>	Mohammad Naser Moghadasi	Islamic Azad University, S&R Branch, Tehran, Iran
<i>Professor</i>	Hasan Tavakoli	Baqiyatollah University of Medical Sciences, Tehran, Iran
<i>Professor</i>	Seyedebrahim Afjeii	Shahid Beheshti University, Tehran, Iran
<i>Associate Professor</i>	Hamed Agahi	Islamic Azad University, Shiraz Branch, Shiraz, Iran
<i>Associate Professor</i>	Ahmad Fakharian	Islamic Azad University, Qazvin Branch, Qazvin, Iran
<i>Associate Professor</i>	Amir-Masud Eftekhari-Moghadam	Islamic Azad University, Qazvin Branch, Qazvin, Iran
<i>Associate Professor</i>	Majid Ebnali	Shahrekord University
<i>Associate Professor</i>	Mohammad Sadegh Javadi Estahbanati	Islamic Azad University, Shiraz Branch, Shiraz, Iran



Islamic Azad University , Shiraz Branch  
Journal of Circuits, Data and Systems Analysis



نشریه تحلیل مدارها، داده ها و سامانه ها

# Journal of Circuits, Data & Systems Analysis

