

بررسی عملکرد الگوریتم‌های سه بعدی کانولوشنال AlexNet و GoogleNet در تشخیص بیماری COVID 19 به کمک تصاویر CT

عربی زهره¹، تقی زاده مهدی²

¹ دانشجوی ارشد مهندسی پزشکی، دانشکده مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون arabi.zohre@gmail.com

² استاد گروه مهندسی پزشکی، دانشکده مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون M.taghizadeh@kau.ac.ir

چکیده

بیماری COVID 19 به صورت وحشتناکی بر بیماران و سیستم‌های درمانی تاثیر نهاده است. عدم شناسایی بیماران مبتلا به بیماری COVID 19 منجر به پخش آلودگی شده و این همه‌گیری و گسترش بیماری خود باعث از دست رفتن زندگی انسان‌های بی‌گناه بسیاری است. بیشترین اهمیت در درمان بیماران مبتلا به COVID 19 تشخیص زود هنگام بیماری است تا مانع از بروز مشکلات بیشتر شود. تست PCR روش استاندارد طلایی است که به طور معمول در تشخیص بیماری COVID 19 استفاده می‌شود، هرچند این روش نیز با محدودیت‌هایی از قبیل کمبود نیروی متخصص، زمانبر بودن، تجهیزات آزمایشگاهی پیچیده و امکان ارائه پاسخ‌های اشتباه همراه است، اما تصاویر CT اسکن می‌توانند به طور موثری آزمایش‌های تشخیص PCR را تکمیل نمایند.

در این مقاله تشخیص بیماری COVID 19 به کمک دو الگوریتم سه بعدی شبکه‌های عصبی کانولوشنال AlexNet و GoogleNet با استفاده از تصاویر CT بررسی خواهد شد. عملکرد مدل‌های پیش‌آمورخته فوق، در بررسی تصاویر CT، آزمایش شده و توان تشخیص هر کدام از این الگوریتم‌ها برای مجموعه اطلاعاتی متعارف و به مراتب بزرگتر مشخص می‌شود. در این مقاله از مجموعه تصاویر سه بعدی با فرمت .nii برای 100 بیمار و 100 انسان سالم استفاده شد. تعداد تصاویر برای آموزش و اعتبارسنجی به ترتیب 140 و 60 تصویر بود.

واژه‌های کلیدی

بیماری COVID 19، شبکه‌های عصبی کانولوشنال، AlexNet، GoogleNet، تصاویر CT

1. مقدمه

در ماه دسامبر سال 2019 فاجعه‌ای فراگیر شبیه به بیماری ذات‌الریه، در ووهان چین مشاهده شد. این ویروس که از مرجعی ناشناس آغاز شده بود خیلی زود در تمام کشورها شیوع یافت و یک همه‌گیری جهانی¹ را ایجاد نمود، این ویروس توسط سازمان بهداشت جهانی به عنوان سندروم تنفسی حاد کرونا ویروس² نامیده شد.

بر اساس آمار سازمان بهداشت جهانی تا کنون بیش از 418 میلیون نفر در کل جهان به این ویروس آلوده شده‌اند و بیش از 5 میلیون و 850 هزار نفر از این بیماران جان باخته‌اند، و شایان ذکر است که این اعداد همچنان در حال رشد است. در حال حاضر تست PCR جهت شناسایی این بیماری استفاده می‌شود، اما مقدار حساسیت این روش پایین است و با توجه به نمونه‌گیری‌های متفاوت و زمان نمونه‌گیری، متغیرهای مهم زیادی در بازده این روش اثر مستقیم دارد. از این رو، در کلینیک‌های پزشکی به غیر از اطلاعات به دست آمده از آزمایش‌های پاتولوژی از دیگر روش‌های مفید برای تشخیص بیماری که شامل بررسی مشخصات بالینی و بررسی تصاویر CT اسکن است

¹ PANADEMIC

² SARS COV-2

استفاده می شود. با توجه به حساسیت بالای تصاویر CT، استفاده از آن‌ها به عنوان بهترین جایگزین برای تشخیص بیماری COVID 19 ارائه شده است، بعلاوه می توان آن را به عنوان روشی تکمیل کننده به همراه PCR جهت تشخیص بیماری در نظر گرفت. به طور مشخص تحقیقات بیانگر این است که تصاویر CT توانایی تشخیص سریع بیماری COVID19 را نسبت به تست های PCR دارند. تا کنون اکثر تفسیرهای ارائه شده در مورد تصاویر پزشکی توسط متخصصان انسانی مانند رادیولوژیست ها و پزشکان در کلینیک انجام شده است. با این حال، به دلیل پیچیدگی تصاویر پزشکی و تفاوت های گسترده ای که در بین تخصص های مختلف در افراد وجود دارد، تشخیص کارآمد و دقیق همیشه برای رادیولوژیست ها و پزشکان بسیار دشوار است. از آنجایی که تفسیر و تحلیل تصاویر پزشکی کاری خسته کننده است که توسط متخصصان انسانی انجام می شود، بنابراین فناوری های رایانه ای می توانند برای کمک به پردازش تصاویر پزشکی استفاده شوند.

در طی چندین سال گذشته، پزشکی هوشمند با ادغام انواع فن‌آوری‌های کامپیوتری پیشرفته، مانند: *هوش مصنوعی، اینترنت اشیا، داده‌کاوی و استفاده از محاسبات ابری در پزشکی*، پیشرفت زیادی کرده است [1,2]. هدف مورد انتظار پزشکی هوشمند ارائه خدمات پزشکی فراگیر و شخصی سازی شده است تا هرکسی بتواند در هر زمان و مکان از مراقبت های بهداشتی هوشمند بهره مند شود. یکی از کاربردهای معروف پزشکی هوشمند در تشخیص به کمک رایانه، استفاده از تکنیک های یادگیری عمیق برای تجزیه و تحلیل تصاویر پزشکی است [3,4]. در چنین برنامه‌ای، مدل یادگیری عمیقی طراحی شده، که تصاویر جمع‌آوری شده از اشعه ایکس، تصویربرداری تشدید مغناطیسی (MRI) و توموگرافی کامپیوتری (CT) را به عنوان ورودی می‌گیرد و سپس نوع بیماری و گاهی اوقات وجود یا عدم وجود بیماری را در خروجی بیان می نماید.

یکی دیگر از کاربردهای موفق پزشکی هوشمند، حسگرهای پوشیدنی برای خود ارزیابی و نظارت بیمار است. آنها در نظارت بر سلامت، فعالیت، تحرک و وضعیت ذهنی، در هر زمان و هر مکان برای تشخیص بیشتر و ذخیره داده ها استفاده می شوند [5,6]. متداول ترین مدل یادگیری عمیق، شبکه های عصبی کانولوشن است که تا به امروز بیشترین موفقیت را در تجزیه و تحلیل تصویر پزشکی داشته است [7,8]. دلیل اصلی استفاده روزافزون از CNN ها این است که در مقایسه با الگوریتم‌های یادگیری ماشین معمولی مانند SVM، KNN، SVM، رگرسیون لجستیک و غیره مهندسی ویژگی آن‌ها مورد نیاز نیست [9,10].

قبل از CNN، باید زمان زیادی را برای انتخاب ویژگی (الگوریتم‌هایی برای استخراج ویژگی) صرف کنیم یا به جای آن از مشخص نمودن ویژگی‌ها به صورت دستی استفاده کنیم، که کارایی پایینی دارد و دقیق نیست. بنابراین CNN ها نسبت به وظایف تشخیص تصویر معمولی و همچنین سایر وظایف از NN ها بهتر عمل می کنند. اخیراً CNN ها به دلیل عملکرد فوق العاده آنها در تصویربرداری پزشکی و توانایی استفاده آنها با GPU ها به طور گسترده توسط جامعه تحقیقاتی تصویربرداری پزشکی مورد استفاده قرار می گیرند.

در مقاله حاضر در *بخش اول* مقدمه ای مختصر از بیماری COVID19 و معرفی کلی روش های یادگیری ماشین در تشخیص تصاویر پزشکی بیان می شود و در *بخش دوم* دو الگوریتم موفق AlexNet و GoogleNet معرفی خواهند شد. پس از این بخش و در *بخش سوم* نتایج حاصل از این دو الگوریتم ارائه شده و در نهایت در *بخش چهارم* نتیجه گیری و نکات مهم بیان شده در این تحقیق بیان می گردد. در *بخش پنجم* نیز پیشنهادات و نقشه راه برای ادامه تحقیق ارائه خواهد شد.

2. شبکه های عصبی کانولوشنال

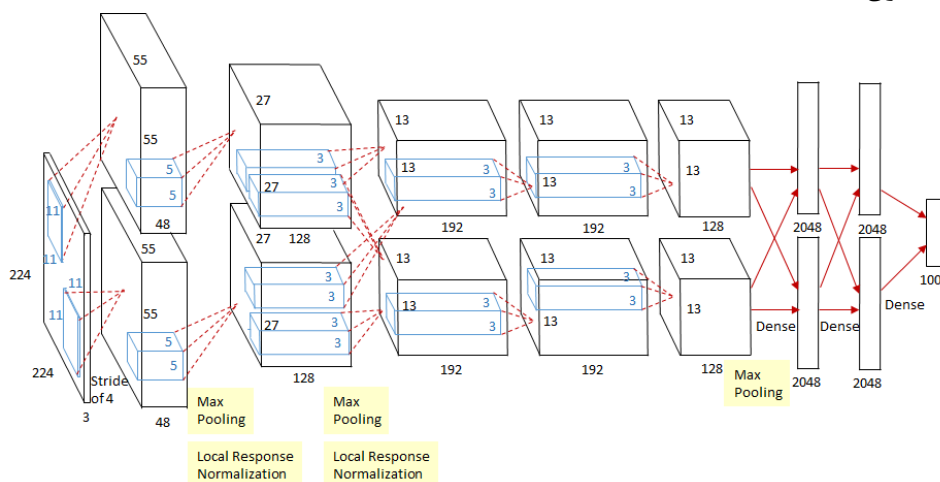
در این بخش، به طور خلاصه شبکه های عصبی کانولوشنال AlexNet و GoogleNet که در تجزیه و تحلیل تصاویر CT اسکن ریه در این مقاله استفاده شده است، ارائه می شود. وظایفی که توسط مدل‌های CNN در تصویربرداری پزشکی انجام می شود را می توان به سه وظیفه اصلی تقسیم کرد: - طبقه بندی، تشخیص و تقسیم بندی. به عنوان مثال، مدل‌های معمولی مانند AlexNet، GoogleNet، VGG و ResNet با الحاق لایه‌های کاملاً متصل به طبقه بندی کننده‌های مختلف، هدف طبقه بندی را دارند. مدل‌هایی از جمله R-CNN، Faster RCNN و YOLO معمولاً برای تشخیص بیماری ها استفاده می شوند و مدل‌های دیگر مانند FCNN و U-Net به طور گسترده برای کار تقسیم بندی استفاده می شوند. همه مدل‌ها در بخش کانولوشنال از معماری‌های بنیادی CNN به عنوان استخراج کننده ویژگی استفاده می کنند.

در ادامه دو الگوریتم AlexNet و GoogleNet به طور خلاصه تشریح می‌شوند:

2.1. بررسی الگوریتم AlexNet

در این قسمت بررسی الگوریتم AlexNet بررسی می‌شود:

2.1.1. معماری



شکل (1): بلاک دیاگرام الگوریتم AlexNet

می‌توان الگوریتم AlexNet را یک شبکه عصبی کانولوشنی عمیق در نظر گرفت که به منظور شناسایی و طبقه‌بندی تصاویر رنگی با سایز $224 \times 224 \times 3$ ارائه شده است. به‌طور کلی این شبکه‌ی عصبی ۶۲ میلیون پارامتر یادگیری و ۱۱ لایه دارد. معماری AlexNet به‌طور همزمان طی ۶ لایه و روی دو GPU Nvidia GeForce GTX 580 آموزش می‌بیند و به همین دلیل، به دو بخش (Pipeline) تقسیم شده است. تصاویر ورودی دارای ابعاد $224 \times 224 \times 3$ می‌باشند.

2.1.2. لایه‌بندی شبکه‌ی عصبی AlexNet

لایه‌های موجود در معماری AlexNet عبارتند از:

لایه‌ی اول (C1): ۹۶ لایه کانولوشن با سایز 11×11 ؛

لایه‌ی دوم (S2): لایه‌ی ادغام (Max Pooling) با اندازه‌ی 3×3 ؛

لایه‌ی سوم (C3): ۱۵۶ لایه کانولوشن با اندازه‌ی 5×5 ؛

لایه‌ی چهارم (S4): لایه‌ی ادغام (Max Pooling) با اندازه‌ی 3×3 ؛

لایه‌ی پنجم (C5): ۳۸۴ لایه کانولوشن با اندازه‌ی 3×3 ؛

لایه‌ی ششم (C6): ۳۸۴ لایه کانولوشن با اندازه‌ی 3×3 ؛

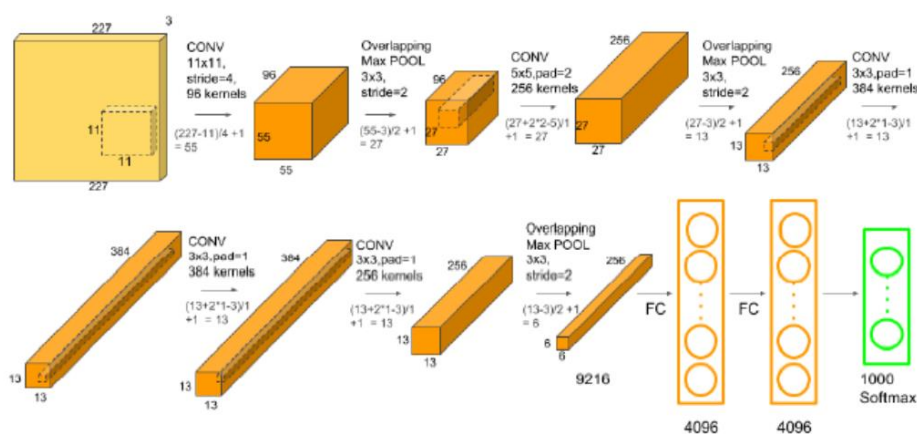
لایه‌ی هفتم (C7): ۲۵۶ لایه‌ی کانولوشن با اندازه‌ی ۳×۳؛

لایه‌ی هشتم (S8): لایه‌ی ادغام (Max Pooling) با اندازه‌ی ۳×۳؛

لایه‌ی نهم (F9): لایه‌ی کاملاً متصل با اندازه‌ی ۴۰۹۶؛

لایه‌ی دهم (F10): لایه‌ی کاملاً متصل با اندازه‌ی ۴۰۹۶؛

لایه‌ی یازدهم (F11): لایه‌ی کاملاً متصل با سایز ۱۰۰۰.



شکل (2): لایه‌های الگوریتم AlexNet

2.1.3. استفاده از پردازنده‌های گرافیکی موازی

در زمان ارائه این الگوریتم از پردازنده گرافیکی NVIDIA GTX 580 استفاده می‌شد که تنها 3 گیگابایت حافظه داشت. بنابراین، در معماری بیان شده طراحی، الگوریتم را به دو مسیر تقسیم نموده و از ۲ GPU برای کانولوشن استفاده نمودند. ارتباطات درونی تنها در یک لایه کانولوشنی خاص رخ می‌دهد. در این الگوریتم، استفاده از 2 پردازنده گرافیکی به دلیل مشکل حافظه و نه برای تسریع روند آموزش است. با مقایسه کل شبکه، با شبکه‌ای که فقط نیمی از هسته‌ها (فقط یک مسیر) دارد، نرخ خطای Top-1 و Top-5 به ترتیب 1.7٪ و 1.2٪ کاهش می‌یابد.

2.1.4. نرمالیزه نمودن پاسخ مقطعی (محلی)

در AlexNet از نرمال سازی پاسخ مقطعی (محلی) استفاده می‌شود. نرمال سازی به سرعت بخشیدن به همگرایی کمک می‌کند. امروزه از نرمال سازی دسته‌ای به جای استفاده از نرمال سازی مقطعی (محلی) استفاده می‌شود. با نرمال سازی مقطعی (محلی)، نرخ خطای Top-1 و Top-5 به ترتیب 1.4٪ و 1.2٪ کاهش می‌یابد.

2.1.5. همپوشانی ادغام

ادغام در همپوشانی ادغام با گامی کوچکتر از اندازه کرنل انجام می‌شود در حالی که ادغام در غیر همپوشانی با گامی برابر یا بزرگتر از اندازه کرنل صورت می‌پذیرد. با ادغام همپوشانی، نرخ خطای Top-1 و Top-5 به ترتیب 0.4٪ و 0.3٪ کاهش می‌یابد.

2.1.6. افزایش داده‌ها

افزایش داده‌ها به دو صورت انجام می‌شود:

2.1.6.1. انتقال تصویر و بازتاب افقی (انعکاس تصویر)

در زمان بررسی تصویر، چهار قسمت گوشه به اضافه قسمت مرکزی و همچنین بازتاب‌های افقی مربوط به آنها (در مجموع 10 قسمت)، برای پیش‌بینی استفاده می‌شود، الگوریتم میانگین همه نتایج را برای به دست آوردن نتیجه نهایی و استفاده از آن در طبقه‌بندی تصویر به کار می‌برد...

2.1.6.2. تغییر شدت روشنایی تصویر

تغییر شدت روشنایی تصویر (PCA) روی مجموعه آموزشی انجام می‌شود و برای هر تصویر آموزشی، مقدار روشنایی تصویر را با استفاده از فرمول زیر اضافه می‌نماید:


$$[P_1, P_2, P_3][\alpha_1\lambda_1, \alpha_2\lambda_2, \alpha_3\lambda_3]^T \quad (1) \text{ تغییر مقدار شدت روشنایی تصویر}$$

که در آن P_i و λ_i به ترتیب بردار ویژه و مقدار ویژه ماتریس کوواریانس 3×3 از مقادیر RGB پیکسل هستند و α_i متغیر تصادفی با میانگین 0 و تغییر استاندارد 0.1 است.


2.1.7. خارج نمودن نرون از لایه‌های الگوریتم

در حین آموزش، هر نرون این احتمال را دارد که در گذر به جلو و پس انتشار مشارکت نداشته باشد. بنابراین، هر نرون می‌تواند شانس برای آموزش داشته باشد و شبکه به نرون بسیار «قوی» وابسته نیست. در طول زمان آزمایش، خروجی نرون وجود نخواهد داشت.

در AlexNet، در دو لایه اول که کاملاً متصل هستند خروجی نرون با احتمال 0.5 استفاده می‌شود. خروجی نرون (Dropout) نوعی تکنیک منظم‌سازی برای کاهش بیش از حد تناسب است.



(a) Standard Neural Net



(b) After applying dropout.

شکل(3):خارج نمودن نرون

2.2. 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 پروفسور Yan LeCun است. به این الگوریتم Inception v1 نیز می‌گویند زیرا نسخه‌های 2، 3 و 4 نیز وجود دارند.

معماری شبکه ارائه شده در این الگوریتم کاملاً با VGGNet، ZFNet و AlexNet متفاوت است. این الگوریتم شامل یک لایه کانولوشن 1×1 در وسط شبکه است، و به جای استفاده از لایه‌های کاملاً متصل، از ادغام میانگین کل شبکه (میانگین جهانی) در انتهای شبکه استفاده می‌نماید. این دو تکنیک از مقاله دیگری با نام "شبکه در شبکه" که توسط لین مطرح شده است برگرفته شده اند..

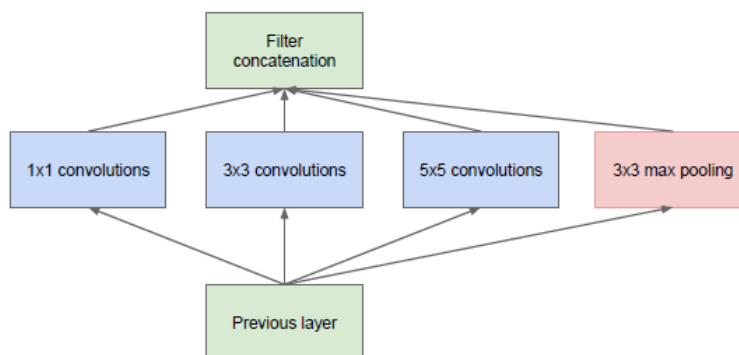
تکنیک دیگر، به نام ماژول دریافت (Inception) وجود دارد که برای ورودی یکسان با اعمال اندازه‌ها، همه خروجی‌ها را ذخیره می‌نماید.

2.2.1. کانولوشن 1×1

کانولوشن 1×1 توسط لین در مقاله شبکه در شبکه که به اختصار آن را NIN می‌نامیم معرفی شده است. در کانولوشن 1×1 از تابع ReLU استفاده می‌شود. نویسندگان در NIN معتقدند داده‌ها به شکل غیرخطی هستند و در اصل این تابع برای افزایش پارامترهای غیرخطی تعریف شده است تا منجر به افزایش قدرت بازنمایی شبکه شود. در GoogLeNet، کانولوشن 1×1 به عنوان یک ماژول کاهش ابعاد برای کاهش محاسبات استفاده می‌شود.

2.2.2. ماژول دریافت

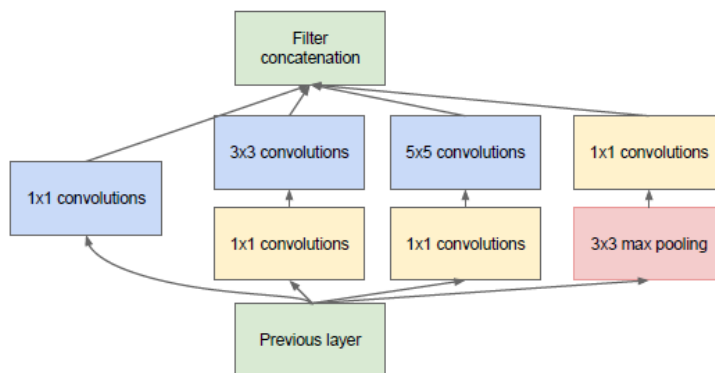
ماژول اولیه (نسخه ساده، بدون کانولوشن 1×1) به شرح زیر است:



شکل(4): ماژول دریافت بدون کانولوشن 1×1


شبهه به الگوریتم‌های AlexNet و VGGNet اندازه کانولوشن برای هر لایه ثابت است. اکنون کانولوشن 1×1 ، کانولوشن 3×3 ، کانولوشن 5×5 ، و حداکثر ادغام 3×3 به طور کلی برای ورودی انجام می‌شود، و تمامی نتایج در خروجی روی هم قرار می‌گیرند. هنگامی که تصویر وارد می‌شود، اندازه‌های مختلف کانولوشن و همچنین حداکثر ادغام امتحان می‌شود. سپس انواع مختلفی از ویژگی‌ها استخراج می‌شوند.

پس از آن، تمام ویژگی‌های حاصل از نگاشت‌های مختلف به عنوان ورودی مازول بعدی به یکدیگر متصل می‌شوند. با این حال بدون تصور وجود کانولوشن 1×1 همانند آنچه بیان شد می‌توان تصور نمود که چه حجمی از محاسبات به وجود خواهد آمد.



شکل(5): مازول دریافت (با کانولوشن 1×1)

2.2.3. ادغام میانگین کل (میانگین جهانی)

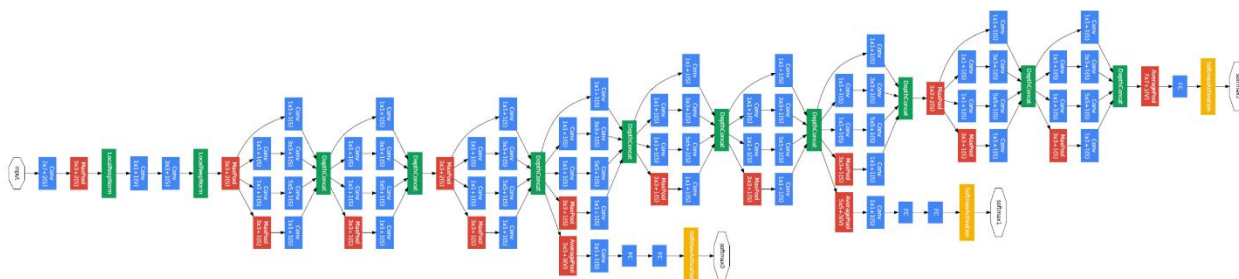


شکل(6): لایه‌های کاملاً به هم متصل در برابر ادغام میانگین کل

در GoogLeNet، ادغام میانگین کل (جهانی) تقریباً در انتهای شبکه استفاده می‌شود و مانند شکل بالا این کار با میانگین‌گیری هر ویژگی نگاشت شده از یک کانولوشن 7×7 به کانولوشن 1×1 ، انجام می‌شود و با جایگزینی لایه‌های FC با ادغام متوسط، دقت تا حدود 0.6% بهبود می‌یابد.

2.2.4. معماری کلی

پس از دانستن بخش‌های اصلی الگوریتم، می‌توان در مورد معماری کلی شبکه صحبت نمود.



شکل (7): شبکه GoogleNet

این شبکه در کل از 22 لایه تشکیل شده است. این شبکه در مقایسه با AlexNet، ZFNet و VGGNet یک مدل بسیار عمیق است. (اما در مقایسه با ResNet که پس از آن اختراع شد، چندان عمیق نیست.) می‌توان دید که ماژول‌های اولیه متعددی به هم متصل شده‌اند تا شبکه عمق بیشتری داشته باشد. (در وسط چند شاخه سافت مکس میانی وجود دارد که در قسمت بعدی در مورد آنها توضیح داده می‌شود.) در زیر جزئیات مربوط به پارامترهای هر لایه آورده شده است. در واقع می‌توان با بسط کانولوشن 1×1 برای تمامی لایه‌ها تعداد عملیات‌های شبکه را محاسبه نمود.

2.2.5. دسته‌بندی‌های کمکی برای آموزش شبکه

همانطور که می‌بینیم چند شاخه سافت مکس متوسط در وسط شبکه وجود دارد که فقط برای آموزش استفاده می‌شوند. این شاخه‌ها طبقه‌بندی‌کننده‌های کمکی هستند که عبارتند از:

5×5 Average Pooling (Stride 3)

1×1 Conv (128 filters)

1024 FC

1000 FC

Softmax

خطا با وزن 0.3 به خطای کل اضافه می‌شود تا الگوریتم با مشکل ناپدید شدن گرادیان مواجه نشود، همچنین این میزان خطا رگولاسیون را تامین می‌نماید.

3. نتایج

در این مقاله از زیر مجموعه‌ای از بانک اطلاعات MosMedData شامل تصاویر سی تی اسکن ریه مبتلا به covid19 استفاده می‌شود. از تصاویر رادیولوژی مربوط به تصاویر سی تی اسکن به عنوان برچسب برای ساخت یک طبقه‌بندی‌کننده که قابلیت پیش‌بینی وجود کرونا را دارد استفاده می‌شود، لذا هدف حل یک مسئله طبقه‌بندی دودویی است.

3.1. بارگذاری اطلاعات و پردازش

فایل‌ها در فرمت Nifti با پسوند .nii ارائه شده‌اند. تصاویر سی تی اسکن با شدت وضوح واکسل خام به واحد هانسفیلد ذخیره می‌شوند. بازه تغییرات شدت وضوح تصاویر در این بانک اطلاعات بین 1024- تا بالای 2000 است. مقادیر بالای 400 استخوان‌ها با مقادیر مختلف رادیوانتنتسیتی (شدت نفوذ پرتو رادیویی) است، لذا به عنوان یک حد بالا استفاده می‌شود. برای نرمالیزه نمودن تصاویر سی تی اسکن به طور معمول از یک حد آستانه بین 1000- تا 400 استفاده می‌شود.

جهت پردازش اطلاعات موارد زیر در نظر گرفته شده است:

ششمین همایش بین‌المللی افق‌های نوین در مهندسی برق، کامپیوتر و مکانیک

6th International Conference on the New Horizons in Electrical Engineering, Computer and Mechanical

www.mhconf.ir

1. ابتدا حجم 90 درجه چرخش داده می‌شود تا جهت تمامی تصاویر ثابت باشد.


2. مقادیر HU تصاویر بین 0 و 1 قرار می‌گیرد.

3. ارتفاع، طول و عرض تصویر دوباره اندازه‌گذاری می‌شود.

در این قسمت توابع کمکی مختلفی برای پردازش اطلاعات تعریف می‌شوند. این توابع در هنگام آموزش الگوریتم و همچنین اعتبارسنجی مجموعه داده‌ها مورد استفاده قرار خواهند گرفت. تصاویر CT از مکانی که پوشه‌های طبقه‌بندی شده قرار گرفته است خوانده می‌شوند.


3.2. ساخت مجموعه اطلاعات آموزش و اعتبارسنجی

تصاویر از پوشه کلاسه‌بندی شده خوانده شده و برچسب‌های آن‌ها مشخص می‌گردد. سپس ابعاد نمونه‌ها به اندازه 128x128x64 تقلیل می‌یابد. مقدار شدت وضوح تصویر باید در بازه 0 تا 1 قرار گیرد و در نهایت زیر مجموعه اطلاعات به دو بخش آموزش و اعتبارسنجی تقسیم می‌شوند. در ذیل یکی از تصاویر CT اسکن مجموعه داده‌ها ارائه شده است.



شکل (8): خروجی تصویر CT اسکن مجموعه داده‌های ارائه شده در این مقاله

با توجه به اینکه تصاویر CT اسکن از مقاطع فراوانی ساخته شده‌اند، لذا در ادامه یکی از تصاویر مونتاژ شده از این مقاطع ارائه می‌گردد.



شکل(9):مقاطع یک تصویر CT

3.3. بررسی عملکرد الگوریتم‌های AlexNet و GoogLeNet

به منظور مقایسه عملکرد الگوریتم‌ها، سه شاخص عملکرد به شرح زیر محاسبه شد:

$$Accuracy = \frac{N_{TN} + N_{TP}}{N_{TN} + N_{FN} + N_{TP} + N_{FP}} \quad (1)$$

$$sensitivity = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (2)$$

$$Specificity = \frac{N_{TN}}{N_{TN} + N_{FP}} \quad (3)$$

در این مقاله موارد مثبت و منفی به ترتیب به مبتلایان به عفونت COVID-19 و افراد غیر مبتلا اختصاص داده شد. از این رو، N_{TN} و N_{TP} به ترتیب نشان دهنده تعداد افراد دارای عفونت‌های COVID-19 و تعداد افراد غیر مبتلا به عفونت COVID-19 هستند که به درستی تشخیص داده شده‌اند. N_{FN} و N_{FP} به ترتیب تعداد افرادی است که به صورت نادرست در مورد آن‌ها وجود عفونت COVID-19 و یا عدم وجود عفونت COVID-19 تشخیص داده شده است.

نتایج حاصل از به کارگیری الگوریتم‌های AlexNet و GoogLeNet برای مجموعه داده‌های در نظر گرفته شده در این مقاله، در جدول زیر ارائه شده است.

جدول 1. عملکرد الگوریتم‌ها

Specificity %	Sensitivity %	Accuracy %	الگوریتم
68.23	89.83	77.88	AlexNet
84.74	83.91	85.23	GoogLeNet

4. نتیجه گیری

در این مقاله، یک بررسی در مورد شبکه‌های عصبی کانولوشن AlexNet و GoogLeNet در تجزیه و تحلیل تصاویر CT ارائه شد. از این بررسی، می‌توان دریافت که این الگوریتم‌های شبکه‌های عصبی کانولوشن، تا حد زیادی به تشخیص بیماری COVID-19 کمک رایانه کمک می‌کنند. علاوه بر این، پارامترهای عملکردی هر دو الگوریتم در تشخیص بیماری تحلیل شد. در نهایت، این نتیجه حاصل

گردید که دقت الگوریتم GoogleNet در تشخیص بیماری بالاتر از الگوریتم AlexNet است اما زمان پاسخ گویی الگوریتم AlexNet به مراتب سریع تر است. در ادامه به برخی از جهت‌های تحقیقاتی آینده برای رسیدگی به چندین چالش باقی مانده از شبکه‌های عصبی کانولوشنال در کاربردهای تشخیص بیماری COVID19 اشاره می‌شود.

منابع

- [1] Selamneni, V., Barya, P., Deshpande, N., Sahatiya, P., 2019. Low-cost, disposable, flexible and smartphone enabled pressure sensor for monitoring drug dosage in smart medicine applications, IEEE Sensors Journal , <https://doi.org/10.1109/JSEN.2019.2935383>.
- [2] Zhang, Q., Bai C., Yang, L.T., Chen, Z., Li, P., Yu, H., 2019. A unified smart Chinese medicine framework for healthcare and medical services, IEEE-ACM Transactions on Computational Biology and Bioinformatics , <https://doi.org/10.1109/TCBB.2019.2914447>.
- [3] Zhang, Q., Bai, C., Chen, Z., Li, P., Yu, H., Wang, S., Gao, H., 2019. Deep learning models for diagnosing spleen and stomach diseases in smart Chinese medicine with cloud computing, Concurrency and Computation: Practice and Experience , <https://doi.org/10.1002/cpe.5252>.
- [4] Liu, Z., Bai, C., Yu, H., Zhu, Y., Wu, T., Bu, F., Zhang, Q., 2019. An adaptive deep learning model to differentiate syndromes of infectious fever in smart medicine, Future Generation Computer Systems, <https://doi.org/10.1016/j.future.2019.09.055>.
- [5] Chan, M., Esteve, D., Fourniols, J., Escriba, C., Campo, E., 2012. Smart wearable systems: current status and future challenges, Artificial Intelligence in Medicine 56 (3) 137–156.
- [6] Haghi, M., Thurow, L., Stoll, R., 2017. Wearable devices in medical internet of things: Scientific research and commercially available devices, Healthcare Informatics Research 23 (1) 4–15.
- [7] Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M.P., Shyu, M., Chen, S., Iyengar, S.S., 2019. a survey on deep learning: algorithms, techniques, and applications, ACM Computing Surveys 51 (5) 92.
- [8] Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., Alasaadi, F.E., 2019. A survey of deep neural network architectures and their applications, Neurocomputing 234 11–26.
- [9] Zhang, Q., Yang, L.T., Chen, Z., Li, P., 2018 High-order possibilistic c-means algorithms based on tensor decompositions for big data in IoT, Information Fusion 39 72–80.
- [10] Zhang, Q., Yang, L.T., Chen, Z., Li, P., 2017. PPHOPCM: Privacy-preserving high-order possibilistic c-means algorithm for big data clustering with cloud computing, IEEE Transactions on Big Data.
- [11] Krizhevsky, A., Sutskever, I., Hinton, G., 2012 ImageNet Classification with Deep Convolutional Neural Networks. Neural Information Processing Systems. 25. 10.1145/3065386.
- [12] Alrahhal, M., K P, S., 2021, COVID-19 Diagnostic System Using Medical Image Classification and Retrieval: A Novel Method for Image Analysis. The Computer Journal, 00(00), <https://doi.org/10.1093/COMJNL/BXAB051>
- [13] Ardakani, A., Kanafi, R., Acharya, U., Khadem, N., Mohammadi, A., 2020. Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks. Computers in Biology and Medicine, 121, 103795. <https://doi.org/10.1016/j.compbimed.2020.103795>
- [14] Bougourzi, F., Contino, R., Distanto, C., Taleb-Ahmed, A., 2021. CNR-IEMN: A Deep Learning Based Approach to Recognise Covid-19 from CT-Scan. 8568–8572. <https://doi.org/10.1109/ICASSP39728.2021.9414185>

- [15] Butt, C., Gill, J., Chun, D., & Babu, B. A., 2020. Deep learning system to screen coronavirus disease 2019 pneumonia. Applied Intelligence. <https://doi.org/10.1007/s10489-020-01714-3>
- [16] Chaudhary, P. K., Pachori, R. B., 2021. FBSED based automatic diagnosis of COVID-19 using X-ray and CT images. Computers in Biology and Medicine, 134, 104454. <https://doi.org/10.1016/J.COMPBIOMED.2021.104454>
- [17] Chollet, F., 2017. Visualizing convnet filters. In Deep Learning with Python (1st ed., pp. 160–172). Manning Publications Co.
- [18] Chollet, F., 2017. Xception: Deep learning with depthwise separable convolutions. Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-January, 1800–1807. <https://doi.org/10.1109/CVPR.2017.195>
- [19] Chowdhury, N. K., Kabir, M. A., Rahman, M. M., Rezoana, N., 2021. ECOVNet: a highly effective ensemble based deep learning model for detecting COVID-19. PeerJ Computer Science, 7, e551. <https://doi.org/10.7717/PEERJ-CS.551>
- [20] Foysal, M., Aowlad Hossain, A. B. M., 2021., COVID-19 Detection from Chest CT Images using Ensemble Deep Convolutional Neural Network. 1–6. <https://doi.org/10.1109/INCET51464.2021.9456387>
- [21] Garain, A., Basu, A., Giampaolo, F., Velasquez, J. D., Sarkar, R., 2021. Detection of COVID-19 from CT scan images: A spiking neural network-based approach. Neural Computing and Applications 2021, –14. <https://doi.org/10.1007/S00521-021-05910-1>
- [22] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H., 2017. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.
- [23] Kamel, M. A., Abdelshafy, M., Abdulrazek, M., Abouelkhir, O., Fawzy, A., Sahlol, A. T., 2021. Efficient Classification Approach Based on COVID-19 CT Images Analysis with Deep Features. Proceedings -IEEE 2021 International Conference on Computing, Communication, and Intelligent Systems, ICCIS 2021, 459–464. <https://doi.org/10.1109/ICCCIS51004.2021.9397189>
- [24] Marques, G., Agarwal, D., de la Torre Díez, I., 2020. Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network. Applied Soft Computing Journal, 96. <https://doi.org/10.1016/j.asoc.2020.106691>
- [25] Muftuoglu, Z., Kizrak, M. A., & Yildirim, T. (2020, August 1). Differential Privacy Practice on Diagnosis of COVID-19 Radiology Imaging Using EfficientNet. INISTA 2020 - 2020 International Conference on INnovations in Intelligent Systems and Applications, Proceedings. <https://doi.org/10.1109/INISTA49547.2020.9194651>
- [26] Shi, Z., Hao, H., Zhao, M., Feng, Y., He, L., Wang, Y., Suzuki, K., 2019. A deep CNN based transfer learning method for false positive reduction, Multimedia Tools and Applications 78 1017–1033.
- [27] Khan, S.U., Islam N., Jan Z., Din I.U., Rodrigues J.J.P.C., 2019. A novel deep learning based framework for the detection and classification of breast cancer using transfer learning, Pattern Recognition Letters 125 1–6.
- [28] Nppi, J.J., Hironaka, T., Regge, D., Yoshida, H., 2016. Deep transfer learning of virtual endoluminal views for the detection of polyps in CT colonography, in: Proceedings of Medical Imaging: Computer-Aided Diagnosis, 97852B
- [29] Zhang, Q., Yang, L.T., Chen, Z., Li, P., Deen, M.J., 2017. Privacy-preserving double projection deep computation model with crowdsourcing on cloud for big data feature learning, IEEE Internet of Things Journal 5 (4) 2896–2903.
- [30] Zhang, Q., Yang, L.T., Chen, Z., Li, P., Bu, F., 2018. An adaptive dropout deep computation model for industrial IoT big data learning with crowdsourcing to cloud computing, IEEE Transactions on Industrial Informatics 15 (4) 2330–2337.

- [31] Perez, L., Wang, J., 2017. The effectiveness of data augmentation in image classification using deep learning, arXiv:1712.04621.
- [32] Emami, H., Dong, M., Nejad-Davarani, S.P., Glide-Hurst, C.K., 2018. Generating synthetic CTs from magnetic resonance images using generative adversarial networks, *Medical Physics* 45 (8) 3627–3636.
- [33] Feng X., Yang J., Laine A.F., Angelini E.D., 2017. Discriminative localization in CNNs for weakly supervised segmentation of pulmonary nodules, in: *Proceedings of International Conference on Medical Image Computing and Computer Assisted Intervention*, pp. 568–576.
- [34] Wang, X., Yang, L.T., Chen, X., Deen, M.J., Jin, J., 2018. Improved multi-order distributed HOSVD with its incremental computing for smart city services, *IEEE Transactions on Sustainable Computing*, <https://doi.org/10.1109/TSUSC.2018.2881439>.