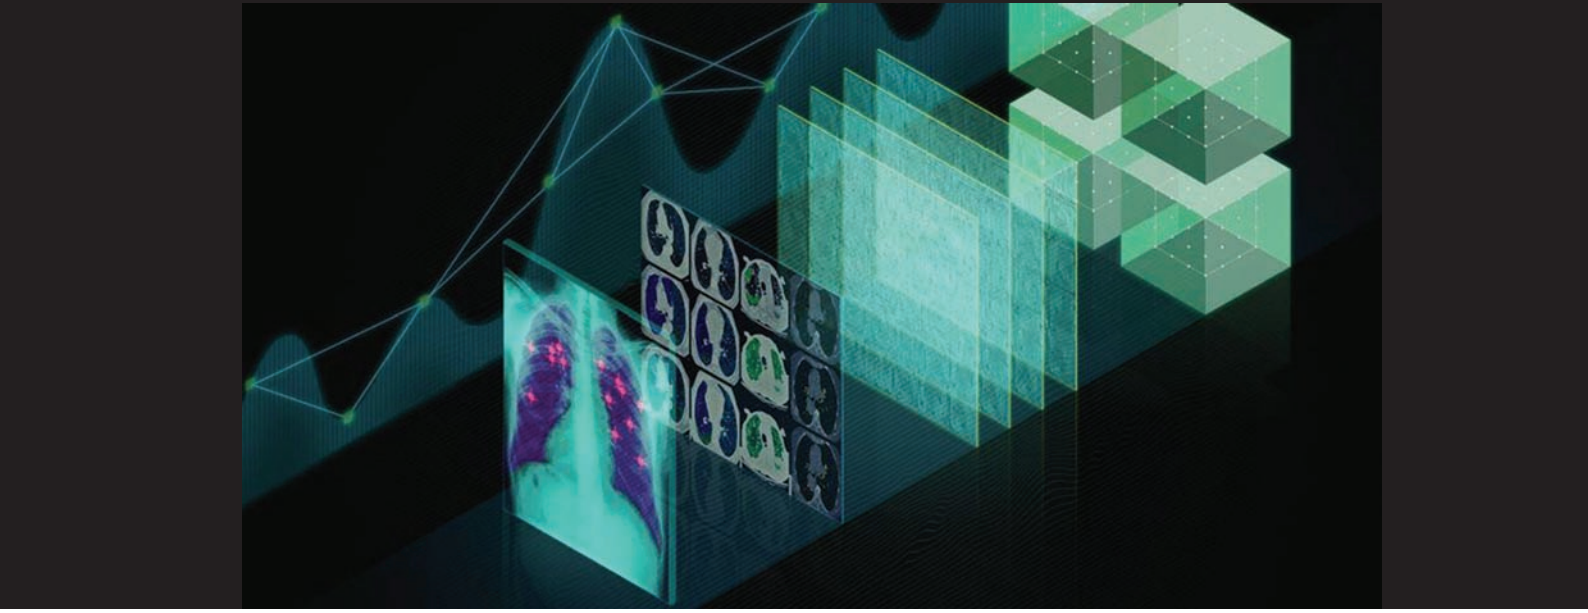

پردازش تصاویر پزشکی با استفاده از شبکه‌های عصبی کانولوشن عمیق

علی کارساز/ استادیار/گروه مهندسی برق –کنترل/ موسسه آموزش عالی خراسان/ مشهد–ایران/karsaz@khorasan.ac.ir

صبورا محمدیان روشن / کارشناسی ارشد/ گروه مهندسی برق و مهندسی پزشکی/ موسسه آموزش عالی خراسان/ مشهد–ایران / saboora.m.roshan@gmail.com

چکیده

حوزه پردازش تصاویر پزشکی بازه وسیعی از کاربردها از تشخیص دیابت چشمی از روی تصاویر شبکیه چشم تا بخش‌بندی تصاویر MRI جهت تشخیص تومورهای مغز انسان را در بر می‌گیرد. نگرش‌های گوناگون دسته‌بندی و خوشه‌بندی مبتنی بر یادگیری ماشین در مقالات جهت بهبود دقت در غربال‌گری بیماری‌ها ارایه شده است. بعضی از این روش‌ها مبتنی بر استخراج ویژگی‌ها از روی تصاویر پزشکی به‌صورت دستی بوده و توسط متخصصان پردازش تصویر با صرف زمان و انرژی زیاد، صورت می‌پذیرد. در سال‌های اخیر روشی جدید برای تشخیص و طبقه‌بندی تصاویر پزشکی بدون نیاز به استخراج ویژگی‌ها به‌صورت دستی، مبتنی بر شبکه‌های عصبی کانولوشن ارایه شده است. این دسته از شبکه‌های عصبی که مبتنی بر فرآیند یادگیری عمیق ارایه شده‌اند نسبت به شبکه‌های عصبی معمولی به علت داشتن لایه‌های کانولوشن و مخفی بیشتر در زمینه کار با ورودی‌های با ابعاد بالاتر مانند تصاویر دارای توانمندی بیشتری هستند. یک معضل جدی در آموزش یک شبکه عصبی کانولوشن با یادگیری عمیق، به موضوع آموزش آنها از ابتدا باز می‌گردد این معضل ناشی از کمبود داده‌های طبقه‌بندی شده جهت آموزش و زمان‌بر بودن فرآیند آموزش تا یک همگرایی مناسب است. بنابراین یک روش متداول برای آموزش شبکه‌های عصبی کانولوشن بر روی داده‌های پزشکی، بر اساس بازتنظیم شبکه‌های از پیش آموزش یافته، می‌باشد. برخی از مهم‌ترین و نیرومندترین شبکه‌های عصبی کانولوشن که بر روی بانک‌های اطلاعات تصاویر، نظیر بانک اطلاعات تصاویر ImageNet با بیش از یک میلیون تصویر، آموزش دیده‌اند شامل شبکه سیفارنت (CifarNet)، الکس‌نت (AlexNet) و گوگل‌نت(GoogleNet) است. که جهت بازتنظیم آنها در تشخیص تصاویر پزشکی با کاربردهای خاص و با تعداد محدودی از تصاویر، می‌توان بهره برد.

کلمات کلیدی: شبکه‌های عصبی کانولوشن، شبکه کانولوشن گوگل‌نت، شبکه الکس‌نت، شبکه سیفارنت، بانک اطلاعات تصاویر ImageNet.

Medical image processing using deep convolutional neural networks

Ali Karsaz /Assistant Professor, Electrical and Bioelectric Engineering Department, Khorasan Institute of Higher Education, Mashhad, Iran
karsaz@khorasan.ac.ir

Saboora Mohammadian Roshan/ M.Sc. Electrical and Bioelectric Engineering Department, Khorasan Institute of Higher Education, Mashhad, Iran/ saboora.m.roshan@gmail.com

Abstract:

The field of medical image processing includes a wide range of applications from automated screening of diabetic retinopathy based on retinal images to MRI segmentation for tumor recognition. Various machine learning classification and clustering approaches have been studied in literature with the purpose of improving the accuracy of the screening methods. Some studies used manually feature extraction of fundus images by image processing experts. In recent years, a new approach for image classification and diagnosis without using any manual feature extraction is proposed based on convolutional neural network (CNN). The CNNs are based on deep learning concept have more convolutional and hidden layers and are more powerful envolving the high dimension inputs such as medical images. In medical imaging and diagnosis, training a deep CNN from scratch is difficult because it requires a large amount of labeled training data and the training procedure is a time consuming task to ensure proper convergence. Therefore, a very common method to train CNNs for medical diagnosis is fine-tuning a pre-trained CNN. Some of these powerful pre-trained CNNs are the GoogleNet, CifarNet and AlexNet which have been trained on the ImageNet as a a large databas

Keywords: Diabetic retinopathy; Convolutional neural network (CNN), GoogleNet, Kaggle retinopathy database.

[Downloaded from kiaeee.ir on 2026-10-08]

۱- مقدمه

مهم‌ترین مزیت استفاده از شبکه‌های عصبی کانولوشن[۱] (CNN) توانایی آن در استخراج ویژگی‌های تصاویر به‌صورت خودکار با استفاده از مفهوم یادگیری عمیق[۲] است[۱،۲]. به‌دلیل همین مزیت بسیار مهم در سال‌های اخیر، استفاده از CNNها برای تشخیص بیماری‌ها در کاربردهای متفاوت پزشکی مورد توجه محققان قرار گرفته است. برای مثال، در زمینه تشخیص رتینوپاتی دیابتی (DR) یا دیابت چشمی که به‌علت بیماری دیابت در این دسته از بیماران، رگ‌های شبکیه چشم تغییر شکل داده و برای خون‌رسانی بهتر گشادتر می‌شوند، از شبکه‌های CNN، جهت استخراج ویژگی‌های تصاویر شبکیه کمک گرفته شده و سپس به روش یادگیری گروهی، رگ‌های خونی شبکیه چشم بخش‌بندی شده‌اند[۳،۴]. از CNNها برای تشخیص مراحل پیشرفت بیماری DR نیز استفاده می‌شود[۵،۶]. همچنین در یک مطالعه دیگر، مقایسه‌ای بین دو ساختار CNN با ابعاد و تعداد لایه‌های چندگانه برای تشخیص هرچه دقیق‌تر DR انجام شده است[۸-۱۰]. از دیگر کاربردهای بکارگیری CNNها در تشخیص و دسته‌بندی می‌توان به تشخیص صحیح پولیپ‌ها[۳][۱۱] در طول فیلم‌برداری کلونوسکپی[۴][۱۲]، تشخیص اتومات رگ‌گرفتگی‌های ریوی[۵] در تصاویر سی‌تی (CT) اسکن[۶] [۱۳]، تشخیص به کمک کامپیوتر تقسیم سلولی[۷] سرطان سینه در بانک‌های اطلاعات پاتولوژی[۱۴]، تشخیص غدد لنفاوی[۸] در تصاویر CT [۱۵]، تشخیص غدد لنفاوی شکمی[۹] [۱۶]، دسته‌بندی بیماری‌های منافذ ریوی[۱۰] [۱۷] و تشخیص اتوماتیک آناتومی در تصاویر CT[۱۸] نام برد. کاربردهای CNNها تنها به موضوع سیستم‌های تشخیصی محدود نمی‌شود بلکه به‌تازگی در زمینه اندازه‌گیری و بخش‌بندی تصاویر حوزه پزشکی نیز دارای عملکرد مناسبی بوده‌اند. برخی از این کاربردها شامل بخش‌بندی لوزالمعده[۱۱] در اسکن توموگرافی [۱۸]، [۱۹]، بخش‌بندی تصاویر مغز کودک[۱۲] [۲۰]، بخش‌بندی غشا عصبی در تصاویر الکترومیکروسکوپی [۲۱]، بخش‌بندی تصاویر غضروف زانو[۱۳] در اسکن MRI [۲۲] و سنجش ضخامت لایه‌های عروق[۱۴] [۲۳] و ده‌ها زمینه دیگر بوده است.

در این مقاله در بخش دوم به بررسی ساختار نوعی یک شبکه عصبی کانولوشن و معرفی لایه‌های مختلف آن پرداخته می‌شود. در بخش سوم، چند نمونه از معروف‌ترین شبکه‌های عصبی کانولوشن از قبیل شبکه سیفارنت[۱۵]، الکس‌نت[۱۶] و گوگل‌نت[۱۷] معرفی و بررسی می‌شوند. درنهایت در بخش چهارم نتیجه‌گیری و جمع‌بندی ارایه می‌گردد.

۲- شبکه‌های عصبی کانولوشن

شبکه‌های عصبی کانولوشن (CNN) مدلی از شبکه‌های عصبی مصنوعی بوده که همانند شبکه‌های عصبی معمولی[۱۸] (TNN) از نورون‌ها، لایه‌ها و وزن‌ها تشکیل شده است. مهم‌ترین تفاوت CNNها با TNNها، به قابلیت ویژه CNNها در یادگیری‌های عمیق مانند تشخیص تصاویر، صداها و دست‌خط‌های متفاوت باز می‌گردد. بنابراین ورودی این شبکه‌ها می‌تواند شامل ماتریس‌هایی از اطلاعات با ابعاد بالاتر باشد. مطالعه‌ای که در سال ۱۹۶۸ میلادی صورت گرفت نشان داد که قشر بینایی مغز برای پردازش اطلاعات تصاویر از الگوی پیچیده‌ای استفاده می‌نماید[۲۴]. نواحی ادراکی که قشر بینایی در آن قرار دارد، همانند فیلترهای محلی بر روی اطلاعات تصویر اعمال می‌شود سلول‌های ساده‌تر برای تشخیص ویژگی‌های سطح پایین‌تر در نواحی ادراکی همچون لبه‌ها کاربرد دارند، همچنین سلول‌های پیچیده قادر به تشخیص ویژگی‌های مهم‌تر و اختصاصی‌تر و در سطوح بالاتر می‌باشند. تشخیص ویژگی‌های اختصاصی‌تر نتیجه و ترکیبی از ویژگی‌های سطح پایین می‌باشند. این عملکرد مغز الهام‌بخش شبکه‌های عمیق عصبی امروزی شده است. مفهوم شبکه کانولوشن برای نخستین بار در سال ۱۹۸۰ توسط فکوشیما[۱۹] مطرح گردید [۲۵]. در سال بعد شبکه‌های کانولوشن امروزی به‌منظور استفاده در شبکه‌های عصبی بررسی شدند. اما به‌دلیل نیاز به سخت‌افزارها و پردازشگرهای گرافیکی قوی استفاده از این شبکه برای تشخیص تصاویر تا سال ۲۰۱۲ که به شکل اختصاصی برای تشخیص تصاویر ارایه و معروف گردید به تعویق افتاد[۲۶].

۲-۱- ساختار شبکه عصبی کانولوشن

شبکه عصبی کانولوشن مدلی از شبکه‌های عصبی چندلایه هستند که به‌طور معمول شامل لایه‌های کانولوشن، پولینگ[۲۰] و تمام متصل[۲۱] (FC) می‌باشند[۲۶]. در یک TNN، شبکه عصبی، ورودی را دریافت و آن را به تعدادی لایه مخفی می‌فرستد. هر لایه مخفی از تعدادی نورون به شکل یک بردار تشکیل شده است که هر نورون به‌طور کامل به تمامی نورون‌های لایه قبلی خود متصل می‌باشد نورون‌ها در هر لایه به‌طور مستقل عمل می‌کنند و در ارتباطات و وزن‌ها با یکدیگر شریک نمی‌شوند. لایه آخر این شبکه، لایه خروجی بوده که مسوول نهایی تعیین کلاس داده‌ها است. اما در CNNها، ورودی یک ماتریس چند لایه یا دارای عمق مانند یک تصویر است و لایه‌های این شبکه بر خلاف TNNها، متشکل از نورون‌هایی در سه بعد هستند. که در برخی از مقالات به آنها تنسور نیز گفته می‌شود.

در این شبکه‌ها نورون‌های یک لایه تنها به ناحیه کوچکی از لایه قبلی متصل می‌باشند و به تمامی نرون‌های لایه قبلی متصل نیستند. شکل (۱) تفاوت شبکه عصبی کانولوشن با شبکه عصبی معمولی را نشان می‌دهد. همان‌طورکه در شکل مشخص است تمامی نورون‌ها در یک TNN به هم متصل می‌باشند اما در یک CNN نورن‌ها در سه بعد قرار گرفته‌اند. در شکل (۱-ب)، لایه‌ی ورودی که با رنگ قرمز مشخص شده است می‌تواند یک تصویر ورودی به شبکه باشد که دارای طول، عرض و عمق بوده و برای تصاویر با فرمت RGB معرف سه کانال قرمز، سبز و آبی در تصویر است[۲۷].

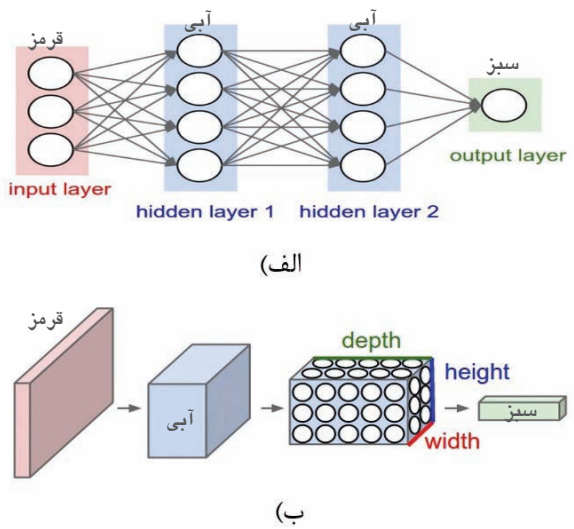

شکل ۱ : مقایسه شبکه عصبی معمولی (TNN) و شبکه عصبی کانولوشن (CNN)، الف) شبکه عصبی معمولی، ب) شبکه عصبی کانولوشن

۲-۱-۱- لایه کانولوشن

این لایه به‌عنوان اصلی‌ترین لایه در این دسته از شبکه‌های عصبی محسوب شده به همین دلیل، آنها را به‌عنوان شبکه‌های عصبی

[Downloaded from kiaeee.ir on 2026-10-08]

کانولوشن می‌شناسند. وظیفه این لایه استخراج ویژگی‌ها است. این لایه عملیات کانولوشن را بر روی داده ورودی اعمال می‌کند و خروجی‌هایی به نام نقشه ویژگی[۲۲] از این لایه بدست می‌آید. در نتیجه تمامی نورون‌ها در یک نقشه ویژگی، مجموعه‌ای از وزن‌ها و بایاس‌های مشابه و مشترکی دارند که باعث می‌شود، ویژگی‌های تصویر در موقعیت‌های مختلف قابل شناسایی باشند. از طرف دیگر این اشتراک وزن‌ها باعث کاهش تعداد پارامترهای مورد نیاز برای آموزش می‌گردد.

در شبکه‌های کانولوشن اتصالات به‌صورت نواحی کوچک و محلی صورت می‌گیرد. به بیان دیگر هر نورون در نخستین لایه مخفی به ناحیه کوچکی از نورون‌های ورودی متصل است. برای مثال این ناحیه می‌تواند ۵×۵ باشد. این ناحیه کوچک ۲۵ پیکسلی ناحیه ادراک محلی[۲۳] یا کرنل کانولوشن [۲۴] نامیده می‌شود[۲۸]. برای توضیح بیشتر می‌توان شکل(۲)، را با یک تصویر ورودی ۲۸×۲۸ در نظر گرفت. پنجره کرنل ۵×۵ بر روی پیکسل‌های ورودی از چپ به راست حرکت می‌کند هر پنجره به نورونی در لایه مخفی متصل می‌شود. بنابراین همان‌طور که در شکل (۲) مشخص است لایه مخفی شامل یک شبکه ۲۴×۲۴ نورونی خواهد بود.

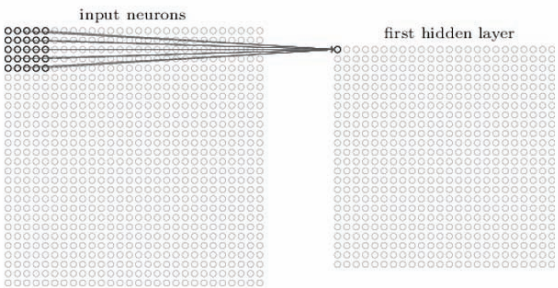

شکل۲ :عملیات کانولوشن در یک CNN با یک کرنل ۵×۵، راست: نورون‌های لایه پنهان، چپ: نورون‌های لایه ورودی

در شکل (۲) هر نورون لایه‌ی مخفی دارای یک بایاس و تعداد ۵×۵ وزن می‌باشد که به ناحیه ادراکی خود متصل شده است. تمامی نورون‌های لایه مخفی مذکور که دارای ابعاد ۲۴×۲۴ خواهد بود، دارای وزن‌ها و بایاس مشترکی می‌باشند. به بیان دیگر خروجی نورون لایه کانولوشن $y_{w,h,m}$ در طول و عرض w، h و عمق m به‌صورت رابطه (۱) قابل بیان است.

$$y_{w,h,m} = f\left(\sum_{i=(w-1)S+1}^{(w-1)S+K}\sum_{j=(h-1)S+1}^{(h-1)S+K}\sum_{k=1}^{N} W_{k,m}x_{i,j,k} + b_m\right) \quad (۱)$$

که در این رابطه f تابع فعالیت[۲۵]، b_m بایاس مشترک نورون‌ها، $W_{k,m}$ وزن‌های ۵×۵ مشترک نورون‌ها و نهایتا $x_{i,j,k}$ ورودی در موقعیت j, i و k می‌باشد. بکارگیری توابع فعالیت در لایه کانولوشن، باعث افزایش خصوصیات غیرخطی در خروجی می‌شوند. توابع فعالیت انواع متفاوتی دارند. چند نمونه از معروف‌ترین توابع فعالیت، تابع سیگموئید[۲۶] ، تابع تانژانت هایپربولیک (tanh)، تابع یکسوساز خطی[۲۷] (ReLU)، تابع خطی نمای[۲۸] (ELU) و Softmax است. بنابراین تمامی نورون‌های واقع در لایه مخفی اول به‌طور دقیق ویژگی مشابهی را در نواحی مختلف تصویر شناسایی می‌نمایند. در نهایت خروجی لایه ورودی یا نورون‌های لایه مخفی به نام نقشه ویژگی شناخته می‌شوند. ابعاد مربوط به ماتریس خروجی لایه کانولوشن $W_2\times H_2\times D_2$ که از ماتریس ورودی با ابعاد $W_1\times H_1\times D_1$ به‌صورت روابط (۲)، (۳) و (۴) به‌دست می‌آید:

$$W2 = \frac{W_1 - F + 2P}{S + 1} \quad (۲)$$

$$H_2 = \frac{H_1 - F + 2P}{S + 1} \quad (۳)$$

$$D_2 = K \quad (۴)$$

در این روابط S, P, F و K به‌ترتیب نشان‌دهنده اندازه کرنل، مقدار zero padding، اندازه‌ی گام و تعداد فیلترها می‌باشد. از این روابط مشخص است که به‌ازای هر فیلتر به مقدار $F\times F\times D_1$ وزن داریم و با توجه به تعداد K فیلتر موجود، در مجموع، تعداد $(F\times F\times D_1)$ وزن و K بایاس ایجاد می‌شود. بنابراین تعداد پارامترهایی که شبکه در یک لایه کانولوشن خود می‌باید آموزش ببیند، بسیار زیاد هستند.

۲-۱-۲-لایه پولینگ[۲۹]

در یک شبکه عصبی کانولوشن به‌طور معمول پس از هر لایه کانولوشن یک لایه پولینگ قرار می‌گیرد. این لایه از آن جهت اهمیت دارد که باعث کاهش تعداد پارامترهایی می‌شود که بایستی آموزش ببینند. بنابراین با بکارگیری این لایه ضمن کاهش محاسبات مورد نیاز در بخش آموزش، باعث کنترل فرایادگیری[۳۰] احتمالی در شبکه نیز می‌گردد. این لایه بر روی هر برش از لایه‌های عمق ورودی اعمال می‌شود و اندازه آن را تغییر می‌دهد. دو تابع عملکردی معروف این لایه، پولینگ بیشینه[۳۱] و میانگین[۳۲] نام دارند، که مدل نخست دارای کاربرد بیشتری در CNNها است. طریقه عمل پولینگ بیشینه بدین صورت است که در هر پنجره، بزرگترین پیکسل را به خروجی می‌فرستد. این پنجره بر روی تصویر همانند تابع کانولوشن از چپ به راست و از بالا به پایین با اندازه گام‌های مشخص شده حرکت می‌کند و نتیجه را به خروجی می‌فرستد. به‌دلیل اینکه این عملیات بر روی تمامی برش‌ها اعمال می‌گردد، عمق خروجی همان عمق ورودی به لایه پولینگ می‌باشد و تغییری نمی‌کند. رابطه مربوط به ماتریس خروجی با ابعاد $W_3\times H_3\times D_3$ که از ماتریس ورودی مرحله کانولوشن با ابعاد $W_2\times H_2\times D_2$ بدست می‌آید به‌صورت روابط زیر می‌باشد.

$$W_3 = \frac{W_2 - F_p}{S_p + 1} \quad (۵)$$

$$H_3 = \frac{H_2 - F_p}{S_p + 1} \quad (۶)$$

$$D_3 = D_2 \quad (۷)$$

در روابط بالا، Fp و Sp به‌ترتیب اندازه ناحیه ادراکی یا کرنل و گام لایه پولینگ می‌باشند. شکل (۳) عملکرد لایه‌ی پولینگ بیشینه را نشان می‌دهد.

۲-۱-۳-لایه‌به‌طور کامل متصل

لایه به‌طور کامل متصل، لایه آخر یک شبکه عصبی کانولوشن محسوب می‌شود و مشابه شبکه عصبی معمولی اتصالات کاملی با خروجی لایه قبلی ایجاد می‌کند. این لایه ورودی را دریافت و سپس خروجی را به‌صورت‌برداری با N مولفه تولید می‌کند. تعداد کلاس‌هایی که شبکه مورد نظر آن را طبقه‌بندی می‌کند برابر با N است. در واقع یک شبکه CNN جهت تولید یک بردار خروجی با

[Downloaded from kiaeee.ir on 2026-10-08]

N مولفـه عددی طراحی می‌شود که هر عـدد در این بردار خروجی، درصد احتمـال تعلق به کلاس مورد نظر را نشـان می‌دهد. بالاترین درصد بیان‌گر نتیجه نهایی آموزش شبکه است[۲۶]. در الگوریتم‌های یادگیـری، بحث مهم در نظـر گرفتن رابطه‌ای بـرای بدست آوردن ارتبـاط بین کـلاس داده مورد نظـر و فرض بدست آمـده از نتیجه آمـوزش الگوریتم می‌باشد. این رابطه که با نـام تابع تلفات نیز از آن یاد می‌شـود بایستی با روش‌های مناسب، بهینه شـود. بنابراین ایده اساسـی در آموزش یـک شبکه و یا الگوریتم یادگیـری، بهینه‌کردن تابـع تلفات با پیمودن گام‌های مناسب بـرای رسیدن به نتیجه بهتر اسـت. روش‌های مهم بهینه‌سـازی برای یـک CNN شامل؛ گرادیان نزولـی، گرادیان نزولی batch، گرادیان نزولی تصادفی و رادیان نزولی mini-batch، الگوریتم Adagrad، الگوریتم RMSprop و Adam می‌باشد. در شبکه‌هـای عصبی کانولوشن به‌دلیـل اینکه تعداد پارامترهایی که آمـوزش می‌بینند بسیار زیاد اسـت و همچنین این دسته از شبکه‌ها دارای لایه‌هـای عمیق هستند بنابرایـن در طی زمان آموزش، شبکه مستعـد فرایادگیـری می‌شود. این به این معنا اسـت که شبکه برای داده‌های آموزش عملکرد خوبی از خود نشان می‌دهد اما این عملکرد بـا وارد شدن داده‌های تست دچـار مشکل می‌شود. برای حل نمودن ایـن مشکـل راه‌های متفاوت بسیـاری پیشنهاد شـده است. یکی از روش‌های معروف، روش افزایش تعداد داده‌های آموزش و روش دیگر، روش اضافـه نمودن لایه dropout مناسب در لایه به‌طور کامل متصل برای رفع این معضل است. روش افزایش داده‌ها در موضوع فرآیندهای یادگیـری، یک روش مرسوم بـوده که در آن با اعمـال تغییراتی در تصاویـر مانند چرخانـدن، بزرگ‌نمایی، جابجایی و غیـره به افزایش تعـداد تصاویر ورودی به شبکه می‌پـردازد. در روش dropout قبل از هر مرحلـه آموزش، تعـدادی از نورون‌ها به‌صورت رنـدم و با نسبت تعیین‌شـده در برنامـه مورد نظـر از فرآیند آموزش خـارج می‌شوند و تنهـا نورون‌هـای باقی‌مانده در آمـوزش شرکـت می‌کنند [۲۸].

۲-۲- باز تنظیم شبکه‌های از قبل آموزش دیده

در زمینه‌های پزشکی به علت کمبود تعداد تصاویر دارای طبقه‌بندی مناسب، آمـوزش کامل یک شبکه عصبی کانولوشـن بسیار دشوار و یـا غیرممکن اسـت. به‌عنوان مثال در بانـک اطلاعات چشم پزشکی کگـل تنها حـدود ۳۵ هزار تصویـر شبکیه چشم وجـود دارد حال آنکـه یک شبکه عصبی کانولوشن نظیـر آلکس‌نت دارای ۶۰ میلیون

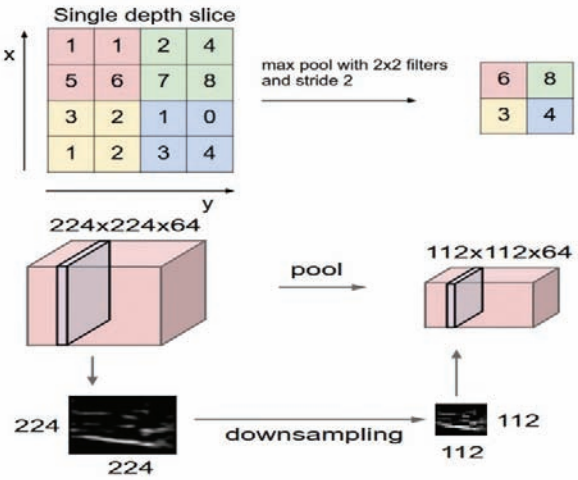

شکل۳: عملکرد لایه پولینگ با کرنل ۲×۲ جهت کاهش پارامترهای مورد آموزش شبکه

وزن جهـت آموزش اسـت. علاوه بر ایـن آموزش شبکـه از ابتدا به سخت‌افزارهـای قوی همانند پردازشگرهای قـوی گرافیکی نیاز دارد که در عمل با محدودیت سخت‌افزاری بیان شده آموزش این شبکه‌ها از ابتـدا ناممکن می‌باشـد[۲۹]. بنابراین به دو روش استخراج ویژگی و یـا استفاده از روش بازتنظیم یک شبکـه از پیش آموزش دیده در لایه‌هـای انتهایی آن می‌توان عمل نمـود. در روش استخراج ویژگی، بـه کمک یـک CNN، ویژگی‌های تصاویر پزشکـی بدست آمده و به کمک یک روش طبقه‌بندی، هماننـد ماشین بردار پشتیبان می‌توان بـه دسته‌بنـدی مورد نظـر دست یافـت. این شیوه بـرای زمانی که تعـداد نمونه‌هـای بسیار کمی موجـود است دارای کاربـرد بوده در ایـن حالت بایستـی ابتدا ویژگی‌هـای تصاویر را بـه کمک لایه‌های کانولوشـن و پولینگ استخـراج نموده و در نهایت ایـن ویژگی‌ها را به‌عنـوان ورودی بـه الگوریتم‌هـای طبقه‌بندی داد، تـا طبقه‌بندی نهایی صـورت گیرد. اما زمانـی که تعداد نمونه‌هـا بیشتر است ولی به اندازه‌ای نیسـت که بتوان کل پارامترهای شبکه را از ابتدا آموزش داد، و ایـن نمونه‌هـا با داده‌های آموزش شبکه اصلـی بسیار متفاوت باشنـد بایستی دوباره از تنظیم یا بازتنظیم شبکه استفاده شود[۲۹]. در روش بازتنظیـم یـک CNN، ابتـدا یک شبکه آمـوزش دیده که

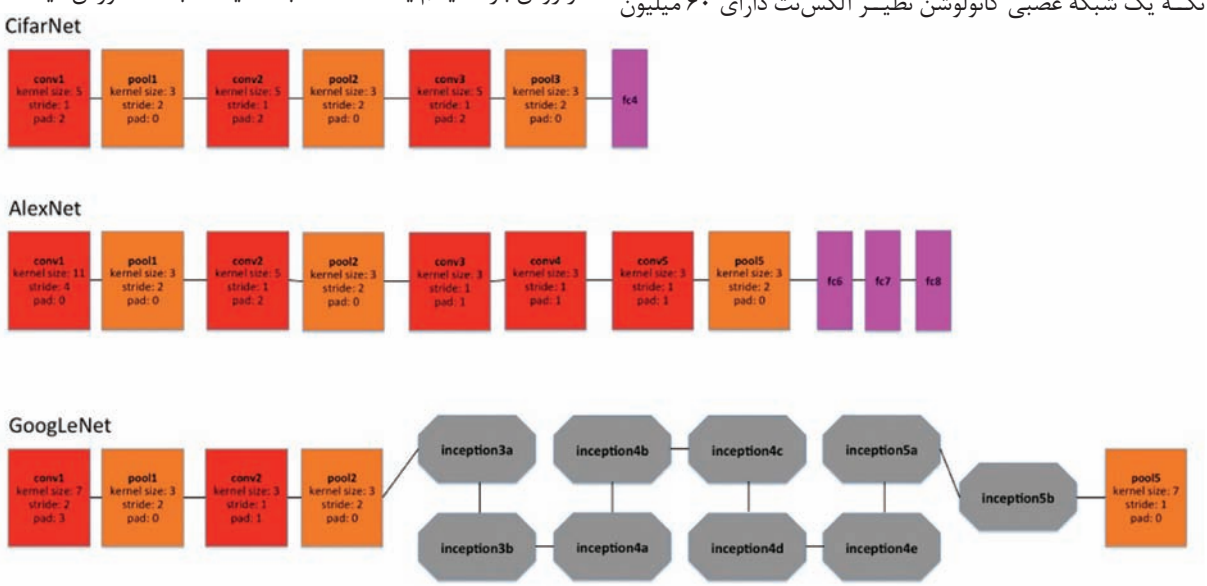

شکل ۴: نمایش ساده‌ای از ساختار سه شبکه عصبی کانولوشن معروف سیفارنت، آلکس‌نت و گوگل‌نت[۱۶]

[Downloaded from kiaeee.ir on 2026-10-08]

نتایج بسیار خوبی در بانک‌های تصاویر مطرح بدست آورده انتخاب می‌گردد، سپس لایه تماماً متصل نهایی با لایه تماماً متصل مورد نظر که قابلیت طبقه‌بندی به تعداد کلاس‌های مورد نظر را دارد، جایگزین می‌شود. در این فرآیند وزن‌های لایه‌های اولیه شبکه اصلی بدون تغییر وارد شبکه مورد نظر جدید می‌شوند و لایه‌های نهایی شبکه دوباره آموزش می‌بینند تا شبکه مورد نظر قابلیت طبقه‌بندی تصاویر جدید را داشته باشد. برخی از شبکه‌های عصبی کانولوشن معروف که در چند سال اخیر معرفی شده‌اند در ادامه مورد بررسی قرار می‌گیرد.

۳- انواع شبکه‌های عصبی کانولوشن

سه نمونه از پرکاربردترین CNNهای موجود به‌خصوص در حوزه پردازش تصاویر پزشکی در این بخش مورد بررسی اجمالی قرار می‌گیرند. این سه شبکه عصبی کانولوشن شامل شبکه‌های سیفارنت، الکس‌نت و گوگل‌نت بوده که جهت بازتنظیم آنها در تشخیص بیماری‌ها و یا بخش‌بندی‌های تصاویر پزشکی می‌توان بهره برد[۱۶]. شکل (۴) ساختار کلی این سه CNN را نشان می‌دهد.

۳-۱- شبکه CNN سیفارنت

سیفارنت اولین بار در دانشگاه تورنتو و در قالب تز دکتری در سال ۲۰۰۹ برای تشخیص اشیای بانک اطلاعات تصاویر سیفار۱۰ معرفی شد[۳۰]. این بانک اطلاعات تصاویر شامل ۶۰۰۰۰ عکس با ابعاد ۳۲×۳۲ و در ۱۰ کلاس مختلف بوده لذا به ازای هر کلاس ۶۰۰۰ عکس متفاوت کوچک وجود دارد. شکل (۵) نمونه‌ای از تصاویر این بانک اطلاعاتی را نشان می‌دهد. سیفارنت دارای سه لایه کانولوشن، سه لایه پولینگ و یک لایه تماما متصل می‌باشد.

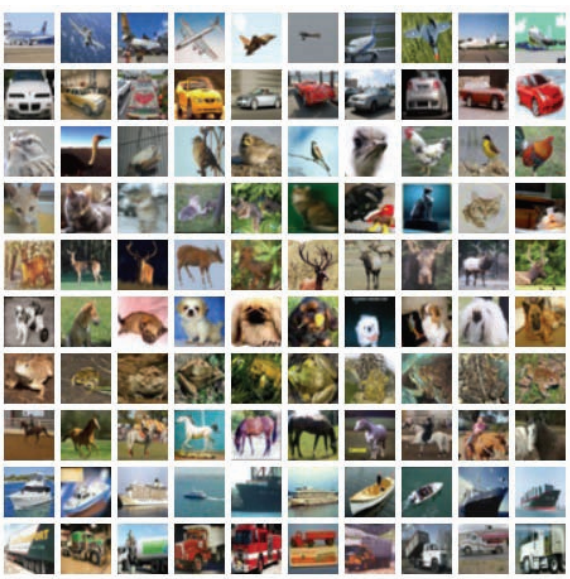

شکل ۵: چند نمونه از تصاویر بانک اطلاعاتی سیفار۱۰، شامل ۶۰۰۰۰ عکس در ۱۰ کلاس متفاوت با ابعاد ۳۲×۳۲

۳-۲- شبکه CNN الکس‌نت

این شبکه در ۲۶امین کنفرانس سیستم‌های پردازش اطلاعات عصبی در سال ۲۰۱۲ معرفی گردید[۲۶]. این شبکه برتری خود را بر شبکه‌های عصبی غیر عمیق برای تشخیص تصاویر در مسابقه معروف تشخیص تصاویر ابعاد بزرگ ImageNet2 به اثبات رساند[۳۱]. بانک اطلاعات ImageNet شامل ۱/۲ میلیون تصویر با ابعاد ۲۵۶×۲۵۶ بوده که در ۱۰۰۰ کلاس مختلف گردآوری شده‌اند. شکل (۶) چند نمونه از تصاویر این بانک اطلاعات تصاویر را نشان می‌دهد. الکس‌نت شامل ۵ لایه کانولوشن، سه لایه پولینگ و دو لایه تماما متصل بوده و حدود ۶۰ میلیون پارامتر آزاد جهت آموزش دارد.

۳-۳- شبکه CNN گوگل‌نت و مدل Inception-v^3

شبکه عصبی کانولوشن گوگل‌نت به‌عنوان عمیق‌ترین شبکه CNN در بین مدل‌های رایج بوده مهمترین وجه تمایز این شبکه نسبت به مدل‌های قبلی مانند الکس‌نت یا سیفارنت استفاده از ماژول Inception در ساختار خود است[۱]. به شکل کلی یک شبکه کانولوشن گوگل‌نت دارای دو لایه کانولوشن، دو لایه پولینگ و ۹ لایه Inception بوده هر لایه Inception خود دارای ۶ لایه کانولوشن و یک لایه پولینگ است. شکل (۷) ساختار یک گوگل‌نت را نشان می‌دهد. مدل Inception-v^3 به‌عنوان یک مدل پیشرفته از شبکه عصبی کانولوشن گوگل‌نت، اولین بار توسط Szegedy و همکاران در سال ۲۰۱۵ معرفی گردید [۲]. در این مدل، کانولوشن‌های ۱×۱، ۳×۳ و ۵×۵ در یک ماژول یکسان و بر روی یک ورودی اعمال می‌شوند و خروجی تمامی این فرآیندها با یکدیگر الحاق شده تا به‌عنوان ورودی لایه بعدی در نظر گرفته شوند. شکل (۸) یک ماژول Inception از شبکه کانولوشن گوگل‌نت را نشان می‌دهد. به دلی-ل الحاق مذکور نام دیگر ماژول Inception، استخراج‌کننده‌ی ویژگی چندلایه می‌باشد.

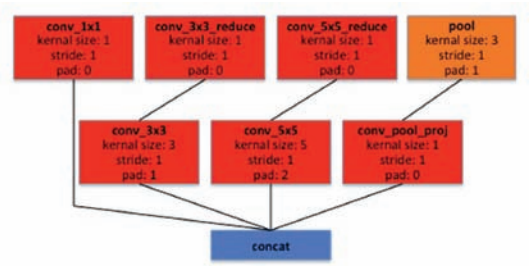

شکل ۸: یک ماژول Inception-a3 از شبکه عصبی کانولوشن گوگل‌نت

۴- نتیجه‌گیری

شبکه‌های عصبی مصنوعی کانولوشن در طول کمتر از یک دهه گذشته با توسعه قدرت پردازش کامپیوترها، در حوزه یادگیری عمیق سهم به‌سزایی را ایفا نموده به‌گونه‌ای که در کاربردهای مهم و حیاتی مانند پردازش تصاویر پزشکی و سیستم‌های اتومبیل خودران با موفقیت‌های روزافزونی همراه بوده‌اند.

بکارگیری شبکه‌های کانولوشن از قبیل سیفارنت، گوگل‌نت و الکس‌نت به‌علت استفاده از لایه‌های عمیق بیشتر در مقایسه با شبکه‌های عصبی متداول، می‌تواند در پردازش تصاویر پزشکی و مقوله غربالگری بیماری‌ها تحول چشم‌گیری را ایجاد نماید.

پی‌نوشت‌ها

1 Convolutional neural network
2 Deep learning
3 Polyp type
4 Colonoscopy videos
5 Pulmonary embolism (PE)
6 CT scan
7 Mitotic cells
8 Lymph nodes
9 Abdominal lymph nodes
10 Interstitial lung diseases
11 Pancreas segmentation
12 Infant brain image segmentation
13 Knee cartilage segmentation
14 Carotid intima-media thickness measurement

[Downloaded from kiaeee.ir on 2026-10-08]

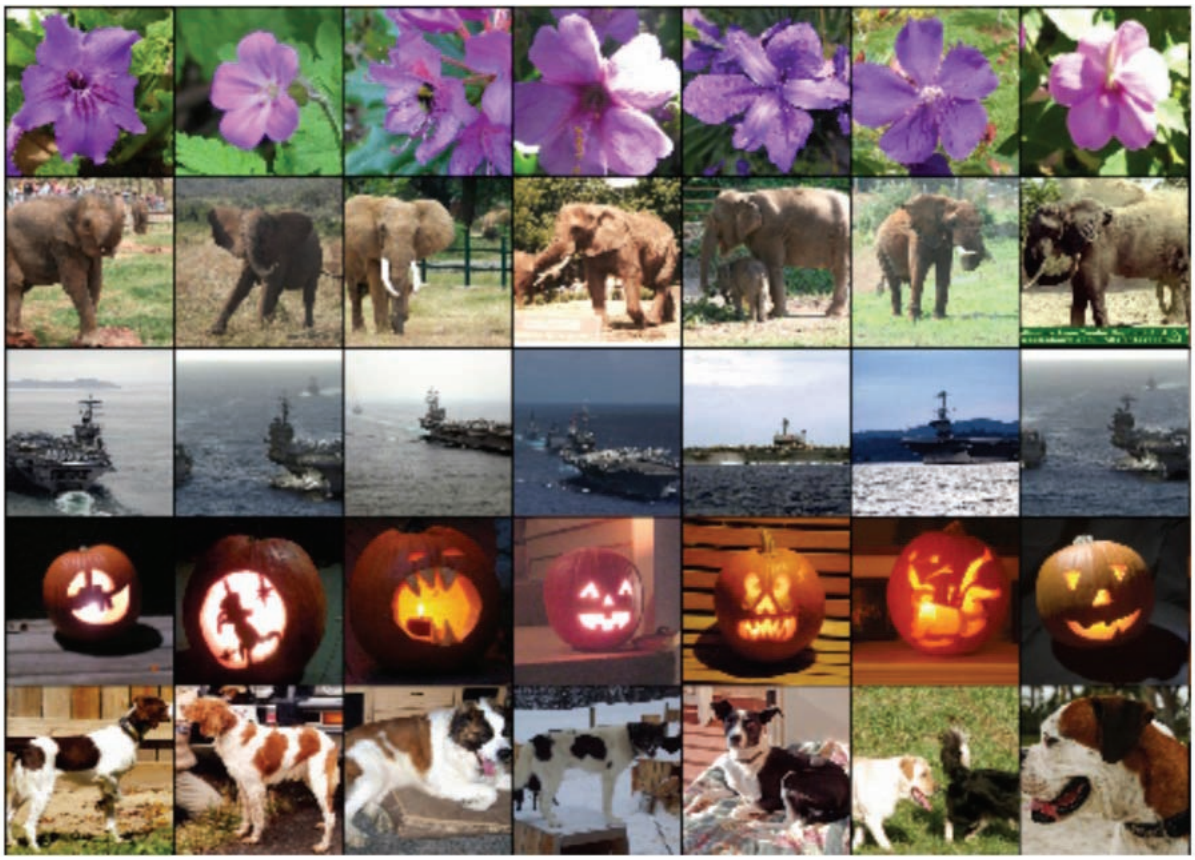

شکل ۶: چند نمونه از تصاویر بانک اطلاعات تصاویر ImageNet، شامل ۱/۲ میلیون تصویر مختلف در ۱۰۰۰ کلاس متفاوت

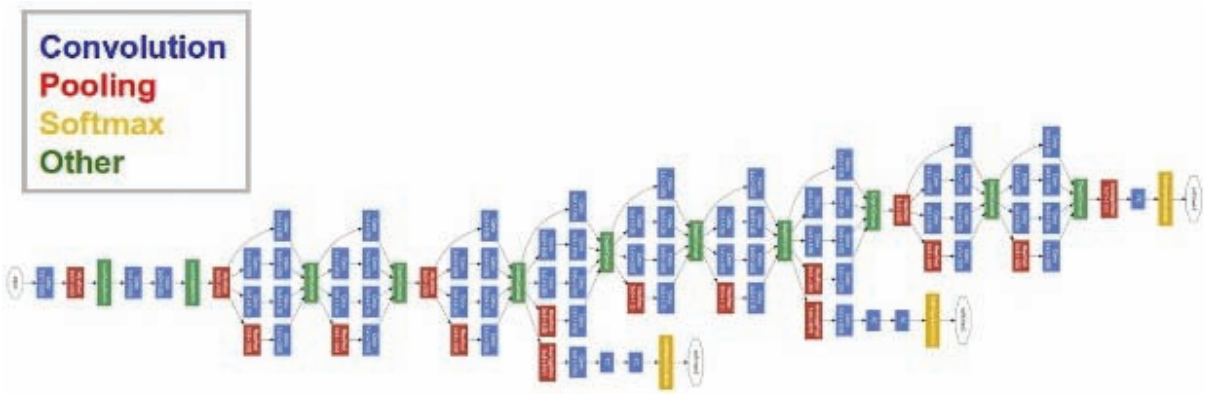

شکل ۷: مدل شبکه عصبی کانولوشن گوگلنت با ماژول‌های Inception به‌عنوان عمیق‌ترین CNN موجود

36 Support vector machine
37 Cifar10 database
38 Neural Information Processing Systems Conference

15 CifarNet
16 AlexNet
17 GoogleNet
18 Traditional neural network
19 Fukushima
20 pooling layer
21Fully connected layer
22 Feature map
23 Local receptive field
24 Convolutional kernel
25 Activation function
26 Sigmoid
27 Rectified linear unit
28 Exponential linear unit
29 Over fitting
30 Max-pooling
31 Average-pooling
32 Adaptive Gradient Algorithm
33 Root Mean Square Propagation
34 Adaptive Moment Estimation
35 Kaggle database

مراجع

[1] C. Szegedy et al., "Going deeper with convolutions," IEEE Conference on computer Vision and Pattern Recognition (CVPR), 2015.
[2] C. Szegedy et al., "Rethinking the Inception Architecture for Computer Vision," IEEE Conference on Computer Vision, Dec. 2015.
[3] Y. Wanga, G. Caoa, B. Weib and G. Yang, "Hierarchical retinal blood vessel segmentation based on feature and ensemble learning," J. Neurocomput., vol. 149, pp. 708–717, Feb. 2015.
[4] F. C. Harry Pratta, Deborah M. Broadbentc, P. Simon P. Hardingac and Y. Zhengac, "Convolutional neural networks for diabetic retinopathy," International Conference On Medical Imaging Understanding and Analysis, July 2016.
[5] H. H. Vo and A. Verma, "New deep neural nets for fine-grained diabetic retinopathy recognition on hybrid color space," IEEE Int. Symposium on Multimedia, Dec. 2016.
[6] Y. M. S. Reddy, R. E. Ravindran and K. H. Kishore, "Diabetic retinopathy through retinal image analysis: A review," Int. J. of Engineering

ادامه در صفحه ۵۹

[Downloaded from kiaeee.ir on 2026-10-08]