



## Fully Connected to Fully Convolutional: Road to Yesterday

Mahmood Amintoosi

Department of Computer Science, Hakim Sabzevari University, Sabzevar, Iran.

[m.amintoosi@hsu.ac.ir](mailto:m.amintoosi@hsu.ac.ir)

**Abstract-** In the last decade, several convolutional networks have been developed for the semantic segmentation, which have shown excellent performance in recognizing and labeling objects in images. Most of these networks involve large-scale architectures that can detect tens or hundreds of predefined classes. With the exception of fully convolutional networks, most applications use architectures that, after convolutional layers, use a common classifier to classify the extracted features. In this paper, the method of converting a network, which as classifier, has two flatten and dense layers (fully connected), to a fully convolutional network is described. The main advantage of this method is the ability to work on inputs of variable size and produce an output map instead of a number, which is the advantage of fully convolutional networks. Newer models of the Deep Learning area generally use training images in which areas of interest are determined by masks; but in the proposed method only labeled images are given to the network. The details of the proposed method are expressed in the form of a new problem of classification of boards with calligraphy of Shekasteh-Nastaliq and Suls, and classification of apple leaf diseases (as two-class problems) and the problem of identifying hand written Persian digits. For this purpose, first a convolutional network with the last fully connected layer is designed and trained for square images. Then a new fully convolutional model is defined based on the previous model and the weights of the previous model are fed to the new model. The only difference between the two models is in the last layer, but the new model will be able to work on input images of any size. Experimental results show the efficiency of the proposed approach.

**Keywords-** Deep Learning, Convolutional Neural Networks, Image Classification, Object Detection, MultiLayer Perceptron.

## تمام متصل به تمام پیچشی: پلی به گذشته

محمود امين طوسى

دانشکده رياضي و علوم كامپيوتر، دانشگاه حكيم سبزوارى

[m.amintoosi@hsu.ac.ir](mailto:m.amintoosi@hsu.ac.ir)

چکیده- در يك دهه‌ي گذشته شبکه‌های پیچشی متعددی برای قطعه‌بندی معنایی تصاویر ابداع شده‌اند که عملکرد بسیار خوبی در تشخیص و برچسبزنی اشیاء از خود نشان داده‌اند. عمده‌ی این شبکه‌ها متنضم معماری‌های با اندازه‌ی بزرگ هستند که توانایی آشکارسازی دهها یا صدها دسته‌ی از قبل مشخص را داشته باشند. در بیشتر کاربردها از معماری‌های استفاده می‌شود که پس از چند لایه‌ی پیچشی از يك طبقه‌بند معمول برای طبقه‌بندی ویژگی‌های استخراج شده‌ی شبکه استفاده می‌شود. در اين نوشتار روش تبدیل يك شبکه که به عنوان طبقه‌بند دو لایه‌ی مسطح و چگال (تمام متصل) دارد، به يك شبکه تمام پیچشی بیان شده است. مزیت اصلی اين شیوه، قابلیت کارکرد بر روی ورودی‌های با اندازه متغیر و تولید يك نقشه خروجی به جای يك عدد می‌باشد که همان مزیت شبکه‌های تمام پیچشی است. در مدل‌های جدید حوزه‌ی يادگیری عمیق عموماً از تصاویر آموزشی که در آنها نواحی موردنظر با ماسک مشخص شده‌اند استفاده می‌شود، اما در شیوه‌ی پیشنهادی در این نوشتار فقط تصاویر برچسب‌دار (مشخص‌کننده طبقه‌ی کل تصویر) به شبکه داده می‌شود. جزییات روش کار در قالب مسئله‌ی جدید طبقه‌بندی و شناسایی تابلوهای با رسم الخطهای شکسته نستعلیق و ثلث، شناسایی برگ سالم از مريض سيب (به عنوان مسائل دو کلاسه) و مسئله‌ی شناسایی ارقام فارسي بیان شده است. به اين منظور ابتدا يك شبکه پیچشی با لایه آخر تمام متصل طراحی و بر روی تصاویر مربعی آموزش داده می‌شود. سپس مدل تمام پیچشی جدیدی بر اساس مدل قبلی تعریف شده و وزنهای مدل قبلی به مدل جدید کپی می‌شود. تنها تفاوت دو مدل در لایه آخر است، اما مدل جدید قابلیت کار بر روی تصاویر ورودی با هر اندازه را خواهد داشت. نتایج آزمایشات کارایی این شیوه را نشان داده است (کد برنامه در <https://github.com/mamintoosi/FC2FC>).

واژه‌های کلیدی: يادگیری عمیق، شبکه‌های عصبی پیچشی ، طبقه‌بندی تصویر، شناسایی اشیاء، پرسپترون چند لایه

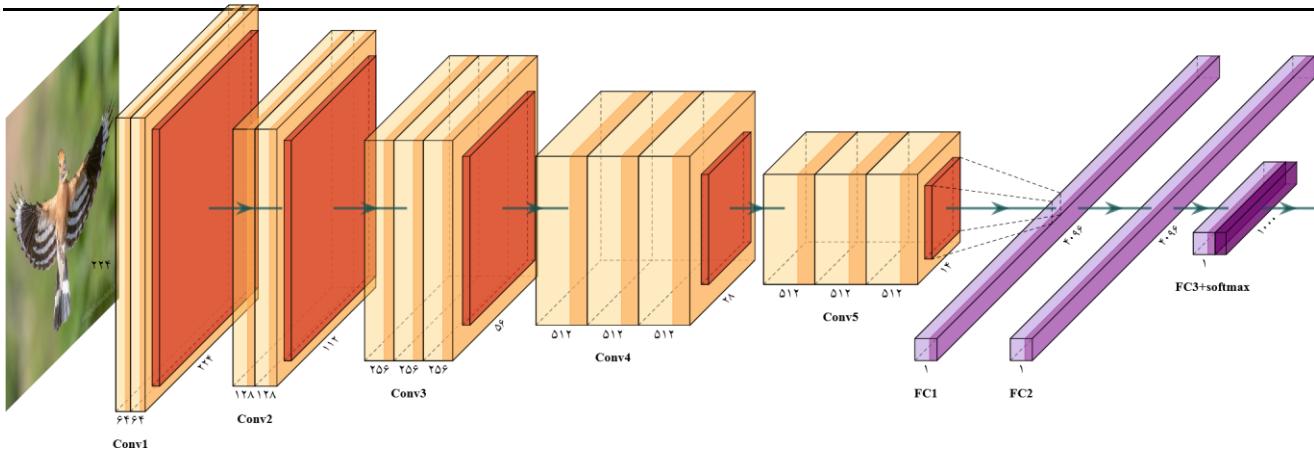
عنوان نمونه، مجموعه داده NYU Depth Dataset [۱] که در گیت‌هاب<sup>۳</sup> مربوط به مقاله [۳] به آن اشاره شده، در نسخه خام، ۴۲۸ گیگابایت و داده‌های برچسب زده آن ۸.۲ میلیون تصویر برچسب زده دارند. این مجموعه داده مربوط به فضاهای داخل می‌باشد. چند نمونه مجموعه داده دیگر در ادامه آمده است:

• مجموعه داده ImageNet<sup>۵</sup> شامل ده میلیون تصویر برچسب زده شده از بیش از ۱۰۰۰ دسته.

• مجموعه داده پاسکال<sup>۶</sup> با بیش از ده هزار تصویر شامل ۲۳۳۷۴ ناحیه علامت زده شده و حجم داده‌های حدود يك و نیم گیگابایت [۱۲]<sup>۷</sup> که شامل طبقه‌های مختلف مانند سگ، گربه

### ۱- مقدمه

در سالیان اخیر شبکه‌های عصبی پیچشی<sup>۱</sup> کارایی چشمگیری در شناسایی الگوهای پیچیده و آشکارسازی اشیاء به نمایش گذاشته‌اند [۱،۲]. روش‌های R-CNN<sup>[۴]</sup>، FCN<sup>[۳]</sup>، MaskR-CNN<sup>[۷]</sup>، YOLO<sup>[۹،۸]</sup>، Faster R-CNN<sup>[۶]</sup> و SegNet<sup>[۱۰]</sup> از جمله تحقیقات پر ارجاع و کارا در این حوزه هستند. داشتن مجموعه دادگان بزرگ که در آن اشیاء مختلف مورد شناسایی، توسط يك کادر یا ماسک در هر تصویر مشخص شده باشند<sup>۲</sup> از الزامات مدل‌های پیچیده جدید این حوزه هستند. به



شکل ۱: معماری مدل VGG16 [۱۵] (چارچوب مدل با استفاده از ابزار سایت [PlotNeuralNet](#) رسم شده است. حق نشر تصویر هدده متعلق به مجید مؤمنی مقدم عضو هیات علمی گروه زیست شناسی دانشگاه حکیم سبزواری است).

در بیشتر مدل های ارائه شده با شبکه های عصبی پیچشی در یادگیری عمیق که با نام شبکه های پیچشی عمیق نیز معروف هستند، در آخرین لایه، یک طبقه بند مانند شبکه های عصبی پرسپترون یا ماشین بردار پشتیبان بکار گرفته می شود. تعویض این طبقه بندها با سایر طبقه بندها از جمله نواوری های مرسوم این حوزه است [۱۹]. عموم طبقه بندها بر روی بردار های ویژگی با طولی یکسان قابلیت کار دارند، به عنوان مثال اگر بردار ویژگی حاصل از آخرین لایه پیچشی یک بردار هزار تایی باشد، ورودی طبقه بند، هزار تایی خواهد بود. اگر به واسطه تغییر اندازه تصویر ورودی به شبکه پیچشی، اندازه این بردار تغییر کند، طبقه بند قادر به عمل نخواهد بود. هدف اصلی این نوشتار بیان نحوه جایگزینی لایه آخر کاملاً متصل<sup>۱۲</sup> با یک لایه پیچشی است، به نحوی که قابلیت عمل بر روی تصاویر با اندازه متغیر فراهم گردد. ایده جایگزینی لایه آخر تمام متصل با لایه پیچشی در FCN [۳] بکار برده شده است. بخش قابلیت عملکرد بر روی تصاویر با اندازه متغیر هم در MaskRCNN [۷] مورد استفاده قرار گرفته است. در این نوشتار نحوه تلفیق این دو و ایجاد مدل های تمام پیچشی با اندازه کوچک به تفصیل بیان شده و برنامه های منبع باز این نوشتار روش کار به صورت عملی را روشن خواهند کرد. در این شیوه نیازی به تصاویر آموزشی که در آن نمونه های مورد طبقه بندی با ماسک مشخص شوند، نیست. گرچه که شیوه مدنظر ربطی به اندازه مدل ندارد، اما در کاربردهای مورد بررسی، مدل هایی کوچک طراح شده است که آموزش آنها به سرعت قابل انجام باشد، قابلیت های مدنظر در نوشتار را داشته و موضوع قابل درک تر باشد.

به نظر می رسد عواملی همچون حجم زیاد مدل های از قبل آموزش دیده در حوزه یادگیری عمیق، معماری های متعدد، پلتفرم های مختلف و پارامترهای فراوان، شاید موجب شده باشد که حرکت از روش های معمول طبقه بندی به شیوه های یادگیری عمیق سخت به

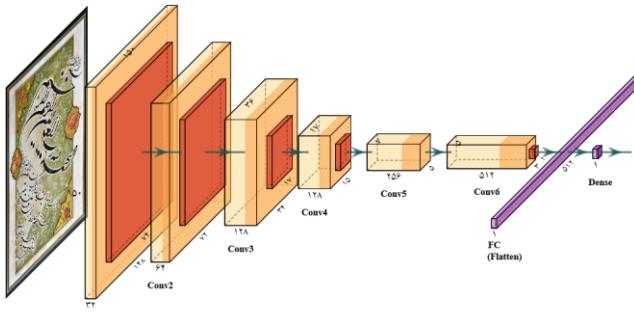
و آسمان است. مجموعه داده های PASCAL-Context که برچسب زنی اضافه تری نسبت به برچسب های پاسکال دارد و توسط روزبه متقی و دیگران [۱۳]<sup>۸</sup> آماده شده است.

- مجموعه داده میکروسافت COCO [۱۴] با ۲.۵ میلیون تصویر.

این مجموعه داده های بزرگ عموماً در ایجاد معماری هایی مانند VGG [۱۵]، AlexNet [۱۶] و DarkNet<sup>۹</sup> [۹] بکار برده شده اند؛ که مبنای بیشتر مدل های مرتبط است. به این مدل ها، مدل از قبل آموزش دیده اطلاق می شود. شکل ۱ ساختار مدل VGG16 را نشان می دهد که بالغ بر ۱۳۰ میلیون پارامتر دارد. در [۱۷] از مدل AlexNet برای تصدیق هویت مبتنى بر اثر انگشت و تصویر چهره فرد استفاده شده است. داشتن حدود ۶۰ میلیون پارامتر در مدل مورد استفاده به عنوان یک نقطه ضعف مدل بر شمرده شده است. ایجاد مجموعه داده های آموزشی که اشیاء مدنظر در هر تصویر با یک کادر یا ماسک برچسب گذاری شوند، مستلزم هزینه و زمان بر است [۱۸]. ساده تر کردن تهیه داده های آموزشی با عنوان شناسایی اشیاء با نظارت مختصر<sup>۱۰</sup> یکی از زیر مسائل شبکه های پیچشی در بینایی ماشین محسوب می شود.

نسخه های مختلف YOLO R-CNN و همگی مبتنى بر یک مدل از قبل آموزش دیده هستند. اندازه این مدل ها معمولاً بسیار بزرگ بوده و شامل میلیون ها پارامتر هستند. برای آموزش چنین مدل هایی حجم زیاد داده و توان پردازشی بالا مورد نیاز است. لذا در بسیاری از تحقیقات بعدی این حوزه، تغییرات مختصی در لایه های آخر این مدل ها برای کاربردهای خاص صورت می پذیرد. به این ترتیب از مدل از قبل آموزش دیده استفاده شده و نیاز به پردازش های سنگین برطرف می شود. در غیر اینصورت مدل باید از پایه طراحی و آموزش داده شود.<sup>۱۱</sup>

با ۴۰۹۶ نورون را شاهدیم و در انتهای آن چگال<sup>۱۶</sup> آخر را داریم که به تعداد کلاس‌ها نورون داشته و از نوع بیشینه نرم<sup>۱۷</sup> است.



شکل ۲: یک نمونه معماری مدل پیچشی-چگال که بخش طبقه‌بند آن شامل یک لایه ۱۲ تایی مسطح (Flatten) و یک لایه چگال (Dense) (Fully Connected) است که کاملاً متصل هستند.

این معماری، ساختار مرسم شبكه‌های پیچشی عمیق است که در ادامه آنرا مدل «پیچشی-چگال» خواهیم نامید<sup>۱۸</sup>. هدف اصلی آن است که بخش طبقه‌بند این معماری با یک لایه پیچشی به نحوی تعویض شود که تعداد پارامترهای مدل ثابت بماند. ثابت ماندن تعداد پارامترها - در کنار مفهوم پارامترها - این اجازه را به ما خواهد داد که با معماری مدل پیچشی-چگال سیستم آموزش داده شده و سپس پارامترهای این مدل در یک مدل تمام پیچشی<sup>۱۹</sup> معادل، کپی شود. طراحی و آموزش مدل پیچشی-چگال ساده است و قابلیت کار بر روی بسیاری از مجموعه دادگان تصویری را دارد. در ادامه در ابتدا نحوه انجام این کار و سپس نحوه اصلاح ساختار مدل برای پذیرش تصاویر با اندازه‌های متنوع بیان خواهد شد.

## ۲- تبدیل مدل پیچشی-چگال به مدل تمام پیچشی

مدل پیچشی-چگال شکل ۲ را در نظر بگیرید. مدل مورد نظر از ۶ لایه پیچشی (Conv1,...,Conv6)، یک لایه کاملاً متصل ۱۲۵ تایی و یک لایه آخر چگال با یک نورون تشکیل شده است. که قابلیت استفاده برای مسائل طبقه‌بندی دو کلاسه را دارد.تابع فعالیت هر لایه پیچشی، واحد خطی اصلاح شده<sup>۲۰</sup> در نظر گرفته شده که با رنگ نارنجی در هر بلوک پیچشی مشخص شده است. لایه‌های نمونه‌بردار (یا انتخاب بیشینه یا ادغام) با رنگ قرمز و لایه‌های مسطح تمام متصل (FC) و چگال با رنگ بنفش مشخص شده‌اند. تابع فعالیت آخرین لایه، یک تابع سیگموئید است که با رنگ بنفش پررنگ نمایش داده شده است. ورودی مدل یک تصویر مربع  $150 \times 150$  است که بعد از گذر از اولین لایه پیچشی با گام یک و اندازه صافی (فیلتر)  $3 \times 3$  به اندازه  $148 \times 148$  می‌رسد. اعداد

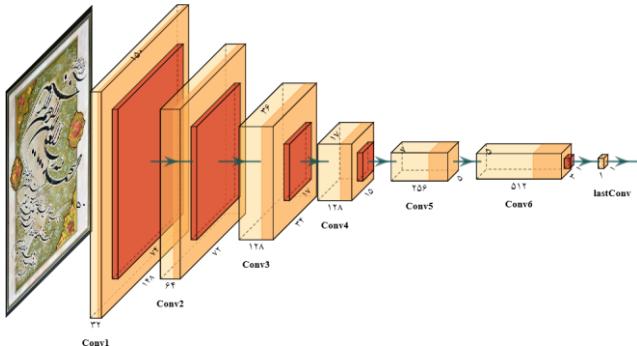
نظر بر سد. آشنایی با شیوه‌ی مورد اشاره در این نوشتار موجب خواهد شد که بسیاری از راه حلها و مجموعه دادگان قبلی آماده شده توسط محققین، به راحتی در بستر یادگیری عمیق، قابل استفاده شده و قابلیت عمل با تصاویر ورودی با اندازه متغیر را هم داشته باشند. برای کاربردهای فراوانی، مجموعه داده‌های آموزشی توسط محققین آماده شده است، اما قابلیت استفاده در شیوه‌های جدید همچون Mask RCNN را ندارند. به عنوان مثال اگر مجموعه دادگانی برای تفکیک دو طبقه در حوزه‌ی پردازش تصویر موجود باشد، قاعده‌تاً تعدادی تصویر از هر دو دسته برای عمل آموزش فراهم شده است (مانند مجموعه تصاویر سگ و گربه در منابع آموزشی یادگیری عمیق)؛ در روش‌هایی مانند Mask RCNN باید دور سوزه‌ی مربوطه در تصاویر آموزشی را با چند ضلعی<sup>۱۳</sup> یا با یک ماسک مشخص نمود. اما در شیوه‌ی پیشنهادی، تصاویر آموزشی در قالب مرسم پیشین (که هر تصویر یک برچسب مشخص دارد)، قابلیت استفاده را خواهند داشت. همچنین معماری مدل به گونه‌ای اصلاح خواهد شد که قابلیت عمل بر روی تصاویر ورودی با هر اندازه را داشته و نقشه‌ای از میزان تعلق هر بخش تصویر به دسته‌های مورد عمل را به دست دهد؛ به جای اینکه تصمیم‌گیری بر روی کل تصویر باشد و طبقه‌ی کل تصویر را مشخص کند.

به عنوان کاربردهایی از شیوه‌ی پیشنهادی، مسائل شناسایی دو رسم الخط مشهور شکسته نستعلیق و ثلث در تابلو نگاره‌ها، تفکیک برگ‌های سالم و مریض درخت سیب و شناسایی ارقام فارسی در نظر گرفته شده است که در بخش ۳ به تفصیل بیان خواهند شد.

## ۲- شیوه‌ی پیشنهادی

همان گونه که در بخش قبل اشاره شد، بسیاری از مدل‌های پیچشی عمیق متنضم چند لایه‌ی پیچشی و در انتهای، لایه‌هایی (هایی) تمام متصل برای طبقه‌بندی می‌باشند. شکل ۱ معماری مدل VGG16 را نشان می‌دهد که همانگونه که ملاحظه می‌شود در آخر، لایه‌های تمام متصل وجود دارد. ابتدا ۵ لایه‌ی پیچشی (هر یک شامل چند لایه‌ی پیچشی و یک لایه‌ی نمونه بردار یا انتخاب بیشینه<sup>۱۴</sup>) وجود دارد که وظیفه‌ی استخراج ویژگی را به عهده دارند. خروجی آخرين لایه‌ی نمونه‌بردار به عنوان ویژگی‌های ورودی یک طبقه‌بند از نوع شبکه‌های عصبی چند لایه در نظر گرفته می‌شوند. این شبکه یک لایه‌ی ورودی ۴۰۹۶ تایی دارد که در شکل ۱ با عنوان FC1 یک لایه کاملاً متصل (به لایه بعدی) است. این لایه در معماري‌های معمول با نام لایه مسطح<sup>۱۵</sup> نامیده می‌شود. سپس لایه پنهان شبکه عصبی

۵۱۲×۱×۱ تصویر ورودی به لایه آخر، با احتساب بایاس، ۵۱۳ پارامتر خواهد داشت. شکل ۳ ساختار مدل تغییر یافته و جدول ۲ جزیات مدل حاصله را نشان می‌دهند.



شکل ۳: معماری مدل تبدیل شده تمام پیچشی. مدل پیچشی-چگال معادل این ساختار در شکل ۲ آمده است.

جدول ۲: خلاصه مدل و پارامترهای مدل تمام پیچشی نمایش داده شده در شکل ۳.

Layer (type)	Output Shape	Param #
Conv1: Conv2D(32, (3,3))	(None, 148, 148, 32)	896
MaxPool1: MaxPooling2D((2,2))	(None, 74, 74, 32)	0
Conv2: Conv2D(64,(3,3))	(None, 72, 72, 64)	18496
MaxPool2: MaxPooling2D((2,2))	(None, 36, 36, 64)	0
Conv3: Conv2D(128,(3,3))	(None, 34, 34, 128)	73856
MaxPool3: MaxPooling2D((2,2))	(None, 17, 17, 128)	0
Conv4: Conv2D(128,(3,3))	(None, 15, 15, 128)	147584
MaxPool4: MaxPooling2D((2,2))	(None, 7, 7, 128)	0
Conv5: Conv2D(512,(3,3))	(None, 5, 5, 256)	295168
Conv6: Conv2D(512,(3,3))	(None, 3, 3, 512)	1180160
MaxPool5: MaxPooling2D((2,2))	(None, 1, 1, 512)	0
lastConv: Conv2D(1,(1,1))	(None, 1, 1, 1)	513
Total params: 1,716,673		

همانگونه که دیده می‌شود، به جای دو لایه آخر مدل قبل، لایه پیچشی lastConv اضافه شده است که عمل طبقه‌بندی به دو کلاس را انجام خواهد داد. حال در صورت داشتن یک مدل آموزش دیده از نوع پیچشی-چگال مناسب، کافیست شبکه تمام پیچشی معادل آنرا تعریف نموده و وزن‌های مدل قبل را در مدل جدید کپی نمود. همان‌گونه که ذکر شد یک لایه پیچشی، جایگزین دو لایه مسطح و چگال آخر گردید. یک نکته اصلی همین موضوع است که این جایگزینی باعث می‌شود در صورت تغییر اندازه‌ی تصویر ورودی، تعداد پارامترهای مدل در مدل تمام پیچشی تغییر نکند، در حالیکه تعداد پارامترها در مدل پیچشی-چگال اولیه، در چنین

بالا و پایین لایه‌های پیچشی بیانگر اندازه‌های ورودی و خروجی می‌باشند.

جدول ۱: خلاصه مدل و پارامترهای مدل پیچشی-چگال نمایش داده شده در شکل ۲.

Layer (type)	Output Shape	Param #
Conv1: Conv2D(32, (3,3))	(None, 148, 148, 32)	896
MaxPool1: MaxPooling2D((2,2))	(None, 74, 74, 32)	0
Conv2: Conv2D(64,(3,3))	(None, 72, 72, 64)	18496
MaxPool2: MaxPooling2D((2,2))	(None, 36, 36, 64)	0
Conv3: Conv2D(128,(3,3))	(None, 34, 34, 128)	73856
MaxPool3: MaxPooling2D((2,2))	(None, 17, 17, 128)	0
Conv4: Conv2D(128,(3,3))	(None, 15, 15, 128)	147584
MaxPool4: MaxPooling2D((2,2))	(None, 7, 7, 128)	0
Conv5: Conv2D(512,(3,3))	(None, 5, 5, 256)	295168
Conv6: Conv2D(512,(3,3))	(None, 3, 3, 512)	1180160
MaxPool5: MaxPooling2D((2,2))	(None, 1, 1, 512)	0
FC: Flatten()	(None, 512)	0
Dense: Dense(1)	(None, 1)	513
Total params: 1,716,673		

خروجی این لایه از یک لایه نمونه‌بردار با اندازه‌ی صافی  $2 \times 2$  عبور داده می‌شود که در نتیجه، اندازه آن نصف خواهد شد. خلاصه مدل و تعداد پارامترهای هر لایه آن در جدول ۱ آمده است. اولین لایه پیچشی با  $32 \times 3 \times 3$  صافی ۸۹۶ پارامتر خواهد داشت؛ ورودی ما تصویر رنگی سه کanalه است، هر صافی یک بایاس هم دارد، لذا  $= 896 \times 3 \times 3 + 1 = 32^2 \times 3 + 1$  پارامترداریم. دقت به این نکته الزامی است که در این مدل تعداد پارامترها ربطی به طول و عرض تصویر ورودی ندارد. از همین نکته در بخش بعد استفاده خواهد شد. لایه نمونه‌بردار بعدی پارامتری ندارد. لایه پیچشی بعدی که  $4 \times 3 \times 3$  صافی را روی  $32 \times 3 \times 3$  تصویر خروجی لایه قبل اعمال می‌کند، ۱۸۴۹۶ پارامتر دارد:  $= 18496 \times (32 \times 3 \times 3 + 1)$ .

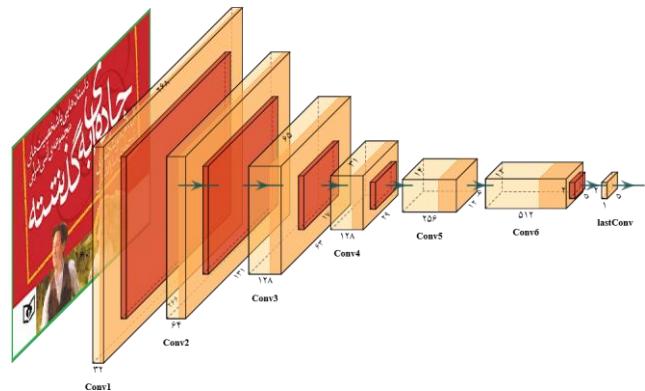
آخرین لایه نمونه‌بردار (MaxPool5) یک لایه بدون پارامتر است که خروجی آن  $512 \times 1 \times 1$  تصویر می‌باشد. این  $512$  عدد مسطح شده و در قالب ورودی به آخرین لایه (Dense) داده می‌شوند؛ با احتساب بایاس، آخرین لایه ۵۱۳ پارامتر خواهد داشت. نکته اصلی آن است که به جای دو لایه مسطح و چگال آخر می‌توان یک لایه پیچشی با اندازه صافی  $1 \times 1$  قرار داد. مشابه با لایه دوم پیچشی که روی خروجی لایه قبل از خود اعمال می‌شد و  $64 \times 3 \times 3$  فیلتر با اندازه  $3 \times 3$  داشتیم، در اینجا هم چون خروجی لایه قبل  $512 \times 1 \times 1$  تصویر است، لذا اعمال یک فیلتر یک در یک روی

کلاسه کارایی داشت. در بخش آزمایشات مثال شناسایی ارقام را هم خواهیم داشت که نمایانگر نحوه عمل برای حالت چند کلاسه خواهد بود.

**جدول ۳:** خلاصه مدل و پارامترهای مدل پیچشی-چگال نمایش داده شده در شکل ۴ برای تصویر با اندازه ورودی  $160 \times 268$ .

Layer (type)	Output Shape	Param #
Conv1: Conv2D(32, (3,3))	(None, 158, 266, 32)	896
MaxPool1: MaxPooling2D((2,2))	(None, 79, 133, 32)	0
Conv2: Conv2D(64, (3,3))	(None, 77, 131, 64)	18496
MaxPool2: MaxPooling2D((2,2))	(None, 38, 65, 64)	0
Conv3: Conv2D(128, (3,3))	(None, 36, 63, 128)	73856
MaxPool3: MaxPooling2D((2,2))	(None, 18, 31, 128)	0
Conv4: Conv2D(128,(3,3))	(None, 16, 29, 128)	147584
MaxPool4: MaxPooling2D((2,2))	(None, 8, 14, 128)	0
Conv5: Conv2D(512,(3,3))	(None, 6, 12, 256)	295168
Conv6: Conv2D(512,(3,3))	(None, 4, 10, 512)	1180160
MaxPool5: MaxPooling2D((2,2))	(None, 2, 5, 512)	0
lastConv: Conv2D(1,(1,1))	(None, 2, 5, 1)	513
Total params:	1,716,673	

حالی تغییر خواهد کرد. این ویژگی باعث می شود که مدل جدید بدون نیاز به آموزش مجدد قابل اجرا بر روی ورودی هایی با هر اندازه باشد.



شکل ۴: معماری مدل مورد استفاده تمام پیچشی روی تصویر مستطیلی با اندازه  $160 \times 268$ .

کل ساختار مدل اولیه باید به گونه ای باشد که این تبدیل ممکن باشد، یعنی در صورت تغییر اندازه تصویر ورودی، تعداد پارامترهای مدل تبدیل شده، تغییر نکند. اگر مشابه معماری VGG یک یا دو لایه مسطح قبل از لایه مسطح آخرين وجود داشته باشد، امکان تبدیل - بدون تغییر تعداد وزنهای - وجود ندارد. در صورت تبدیل دو لایه مسطح و چگال به پیچشی، تعداد پارامترهای لایه های مسطح قبلی، در صورت تغییر اندازه ورودی تغییر خواهد کرد و در نتیجه تعداد کل پارامترهای مدل تغییر خواهد کرد که باعث عدم امکان استفاده از وزنهای مدل اولیه خواهد شد. از آنجا که روش مدنظر در این مقاله، فقط وزنهای مدل اولیه پیچشی-چگال به مدل تبدیل شده تمام پیچشی کپی می شود، بحث آموزش مجدد مدل مطرح نیست و حتماً باید تعداد پارامترهای دو مدل یکسان باشند. ابزارهای مشهور Tensorflow و پای تورج توابع لازم برای کپی کردن وزن ها از یک مدل به دیگری را دارا می باشند. پیاده سازی انجام شده برای این مقاله با Tensorflow<sup>۲۱</sup> است که از گیت هاب مرتبط با این نوشتار<sup>۲۲</sup> قابل دانلود و اجراست.

در تابع set\_conv\_weights از فایل FC2FC.py نحوه کپی وزنهای لایه های چگال آخر مدل پیچشی-چگال به لایه های پیچشی مدل تمام پیچشی ذکر شده است. تابع convert\_model در فایل FC2FC.py برای کپی وزنهای همه لایه های مشابه با هم در جدول های ۱ و ۲ نوشته شده است؛ در این تابع، تابع set\_conv\_weights فراخوانی شده و وزن های لایه های چگال مدل ۲ را به لایه های پیچشی مدل ۳ کپی می کند. ساختارهای دو مدل فوق الذکر به نحوی تعریف شده بودند که کپی پارامترها امکان پذیر باشد. مثال اخیر برای حالت دو

**۲-۲- اصلاح مدل برای پذیرش تصاویر با اندازه های مختلف**  
در بخش قبل نحوه تبدیل یک شبکه پیچشی-چگال به شبکه ای تمام پیچشی بیان شد. اندازه تصویر ورودی در معماری ذکر شده در شکل ۲ و جدول  $150 \times 150$  فرض شده بود. برداشت اولیه آن است که این شبکه فقط با تصاویری با همین اندازه کار می کند؛ در شبکه های پیچشی-چگال به دلیل لایه های تمام متصل آخر (لایه های مسطح و چگال)، این تلقی درست است. اگر در معماری مدل، اندازه تصویر ورودی تغییر یابد، ۶ لایه اول پیچشی قادر به کار هستند، اما اندازه های خروجی های آنها (تعداد ویژگی ها) تغییر خواهد کرد. این تغییر باعث خواهد شد که در لایه مسطح، تعداد نورونها تغییر کرده و در نتیجه تعداد وزنهای و ساختار مدل از این لایه به بعد دستخوش تغییر گردد. اگر به جای لایه های کاملاً متصل آخر، مطابق شیوه های پیشنهادی در بخش قبل، از یک لایه های پیچشی مناسب استفاده شود، شبکه قابلیت کار بر روی تصاویر با اندازه های بزرگتر با مساوی  $150 \times 150$  را خواهد داشت. پس در واقع روش بخش پیش جوابگوی این مشکل هم هست که البته در این بخش به صورت مجزا مورد بررسی قرار گرفته است. فرض کنید اندازه تصویر ورودی  $160 \times 268$  است. اگر اندازه ورودی شبکه بر اساس این اندازه ها تغییر

به این ترتیب تصویر ورودی  $160 \times 268$  منجر به آخرین لایه پیچشی با ابعاد  $(h, w) = (5 \times 2)$  خواهد شد. هر یک از این دو نورون، طبقه‌ی ناحیه مرتبط با خود در تصویر ورودی را مشخص خواهند کرد.

رابطه فوق برای محاسبه  $w$  بر حسب  $x$ ، در صورت تغییر معماری مدل، عوض خواهد شد. به عنوان مثال اگر ساختار شبکه شامل سه لایه پیچشی + نمونه‌بردار باشد که صافی‌های لایه‌های پیچشی  $3 \times 3$  با گام یک و صافی‌های لایه‌های نمونه بردار  $2 \times 2$  باشند،  $w$  به صورت زیر محاسبه خواهد شد:

$$\begin{aligned} w &= \frac{1}{2} \left( \frac{1}{2} \left( \frac{1}{2} (x - 2) - 2 \right) - 2 \right) \\ &= \frac{x - 2^4 - 2}{2^3} = \frac{x - 14}{8} \end{aligned} \quad (3)$$

درخصوص پیاده سازی، نیازی به آموزش مدل جدید نیست. فقط کافیست اندازه ورودی اولین لایه، متناظر با اندازه تصویر ورودی بروزرسانی شده و پارامترهای مدل پیچشی-چگال به این مدل داده شود. مواردی که گفته شد مربوط به مسائل دو کلاسه بودند، اگر تعداد طبقه‌ها بیشتر از دو باشد، کافیست در لایه آخر پیچشی، تعداد نورون‌های  $1 \times 1$  به تعداد کلاس‌ها درنظر گرفته شده و از تابع فعالیت بیشینه نرم استفاده گردد. اگر  $k$  کلاس داشته باشیم، اندازه‌ی آخرین لایه پیچشی  $(h \times w \times k)$  خواهد بود. در ادامه با ذکر چند کاربرد، باجزیات روش کار بیشتر آشنا خواهیم شد.

### ۳- نتایج آزمایشات

در این بخش سه کاربرد با روش پیشنهادی مدلسازی شده‌اند، کاربرداول، مسئله‌ی طبقه‌بندی و شناسایی دو رسم الخط مشهور شکسته نستعلیق و ثلث در تابلو نگاره‌ها و کاربرد دوم تفکیک برگ‌های سالم از مریض درخت سیب است که هر دو مسئله‌هایی دو کلاسه هستند. سومین مورد، شناسایی ارقام فارسی است که دارای ده طبقه می‌باشد. روش پیشنهادی در بستر کراس و تنسورفلو پیاده سازی شده است که از گیت‌هاب نگارنده در آدرس زیر قابل دسترس است:

<https://github.com/mamintoosi/FC2FC>

گرچه که دقت روش در نتایج آزمایشات ذکر شده است، اما هدف از این نوشتار، افزایش دقت یک طبقه‌بند نبوده است؛ هدف اصلی آن است که نحوه‌ی تبدیل یک شبکه‌ی پیچشی-چگال به شبکه تمام پیچشی و کاربرد این تبدیل نشان داده شود. هر مدل پیچشی-چگال مناسب (با هر دقیقی که در دسترس باشد) می‌تواند با این شیوه به یک مدل تمام پیچشی تبدیل شده و قابلیت کار بر

کند، مدل جدید به صورت شکل ۴ خواهد بود که پارامترهای آن در جدول ۳ نمایش داده شده‌اند. اندازه تصویر ورودی با اندازه تصویر  $150 \times 150$  که برای آموزش شبکه استفاده شده تفاوت دارد، مدل هم مقداری تفاوت دارد اما پارامترهای مدل فرق نکرده است. دلیل این موضوع آن است که مدل نمایش داده شده در شکل ۳ تمام پیچشی بوده و هیچ یک از لایه‌ها و پارامترهای آن وابسته به اندازه تصویر ورودی نیستند. البته در زمان تعریف مدل باید اندازه ورودی آن بر حسب اندازه تصویر جدید مشخص شود، که در این حالت معماری مدل به صورت شکل ۴ در خواهد آمد. در آخرین لایه که پیش از این یک لایه پیچشی  $1 \times 1$  داشتیم، اکنون یک لایه پیچشی  $2 \times 2$  داریم. اگر بر اساس اندازه‌های تصویر ورودی و ساختار شبکه پیش برویم به همین اندازه خواهیم رسید. برای مشخص کردن اندازه این لایه در حالت کلی، فرض کنید طول ضلع شکل مستطیلی ورودی در راستای یکی از محورها  $x$  باشد. در اولین لایه پیچشی  $2 \times 2$  تا کم خواهد شد، سپس با گذر از لایه نمونه‌بردار تقسیم بر  $2$  خواهد شد (تقسیم صحیح) و الی آخر. اگر  $W$  پهنای آخرین لایه در راستای همین محور باشد، خواهیم داشت:

$$w = \frac{\frac{x-2}{2}-2}{\frac{\frac{\frac{x-2}{2}-2}{2}-2}{\frac{\frac{\frac{x-2}{2}-2}{2}-2}{2}}-4} \quad (1)$$

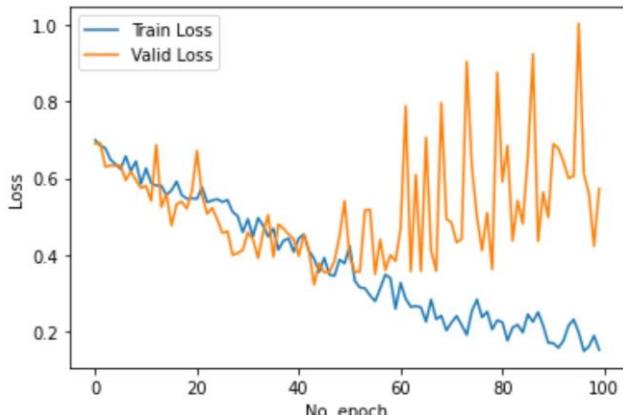
عدد ۴ آخر به دلیل دو لایه پیچشی پشت سر هم  $5 \times 6$  است که بین این دو، لایه پیچشی  $1 \times 1$  نمایش داده شدیم. از آنجا که اندازه ورودی  $150 \times 150$  یکی از اندازه‌های مرسوم این حوزه است (و همچنین میانگین اندازه ورودی‌ها در بخش بعد)، در شبکه فرضی مورد بحث، همین اندازه درنظر گرفته شد. خروجی لایه پیچشی قبل از آخرین لایه نمونه‌بردار باید  $3 \times 3$  باشد که نتیجه نمونه‌برداری  $1 \times 1$  شود. به همین دلیل بین دو لایه پیچشی  $5 \times 6$  لایه نمونه‌بردار قرار داده نشد. با صرفنظر کردن از جزء صحیح، رابطه (۱) به صورت زیر بازنویسی و خلاصه خواهد شد:

$$\begin{aligned} w &= \frac{1}{2} \left( \frac{1}{2} \left( \frac{1}{2} \left( \frac{x-2}{2} - 2 \right) - 2 \right) - 2 \right) - 4 \\ &= \frac{x - 94}{32} \end{aligned} \quad (2)$$

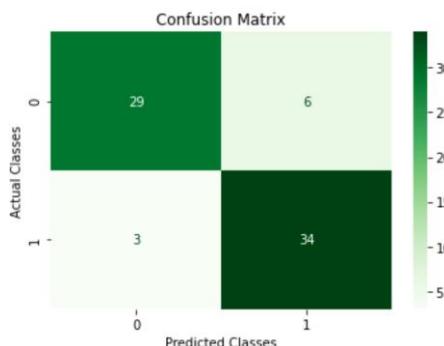
لذا برای تصویر ورودی با طول ضلع  $x = 268$  برابر  $5.44$  خواهد شد که جزء صحیح آن برابر  $5$  خواهد بود. برای ارتفاع تصویر هم مقدار  $h$  برابر با  $2$  خواهد بود:

$$h = \lfloor \frac{y - 94}{32} \rfloor = \lfloor \frac{160 - 94}{32} \rfloor = \lfloor 2.31 \rfloor = 2$$

آموزش، ۷۰ تصویر به عنوان اعتبارسنجی و ۷۲ تصویر باقیمانده به عنوان داده آزمون درنظر گرفته شدند.



شکل ۶: نمودار خطای (زیان) در ۱۰۰ تکرار روی داده‌ها. مدل با کمترین خطای بر روی مجموعه دادگان اعتبارسنجی، به عنوان بهترین مدل انتخاب می‌شود.



شکل ۷: ماتریس درهم ریختگی بر روی مجموعه دادگان آزمون در شناسایی تابلونگاره‌ها. در این اجرا میزان دقت ۸۸ درصد بوده است.

میانگین اندازه تصاویر ورودی  $152 \times 151$  پیکسل است. از مدل پیچشی-چگال شکل ۲ در این مثال استفاده شده است. روش کلی اجرا، به صورت انتهای به انتها<sup>۳۶</sup> بوده و به جز تبدیل از بازه‌ی [۰، ۱] به بازه‌ی [۰، ۱] و داده افزایی<sup>۳۷</sup> پردازش دیگری روی داده‌ها صورت نپذیرفته است. حداکثر زاویه ۴۵ درجه و میزان کم تغییر مقیاس و جابجایی در راستای محورها به عنوان پارامترهای داده‌افزایی در نظر گرفته شده بودند. برای تعیین تعداد اپک<sup>۳۸</sup> بهینه، با اندازه دسته‌ی<sup>۳۹</sup> برابر با ۳۲، صد تکرار روی داده‌ها انجام شده است. شکل ۶ نمودار تغییرات خطای<sup>۴۰</sup> برای داده‌های آموزش و اعتبارسنجی را نشان می‌دهد. مدلی که روی داده‌های اعتبارسنجی کمترین خطای را داشته است به عنوان مدل بهینه انتخاب می‌شود. میزان دقت<sup>۴۱</sup> روی داده‌های آزمون ۸۸ درصد بوده است. شکل ۷ ماتریس درهم ریختگی برای مدل انتخابی را نشان می‌دهد. طبقه‌ی

روی تصاویر با اندازه‌ی ورودی متغیر را داشته باشد؛ لذا موضوع مقایسه با سایر روش‌های طبقه‌بندی مطرح نیست.



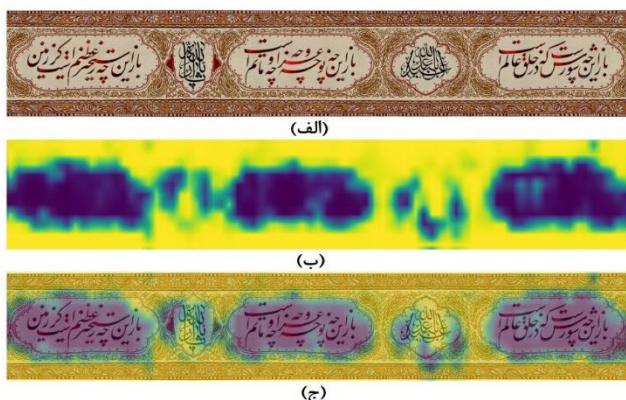
شکل ۵: نمونه تصاویر آموزشی خط شکسته و ثلت که با یک خزنده از گوگل استخراج و پالایش شده اند. دو سطر اول مربوط به خط شکسته و دو سطر آخر، نمونه تابلوهایی با خط ثلت را نشان می‌دهد.

### ۳-۱- طبقه‌بندی تابلونگاره‌های خوشنویسی

مسئله‌ی پردازش خط و زبان فارسی از دیرباز مطرح بوده و کارهای متنوعی در این حوزه انجام شده است.<sup>۳۳</sup> اما تا آنجا که نگارنده می‌داند هنوز کاری درخصوص طبقه‌بندی تابلونگاره‌های خوشنویسی انجام نشده است. شناسایی نوع قلم بکار رفته در متن، به عنوان یک مرحله پیش پردازش در شناسایی بصری حروف فارسی، از اهمیت بالایی برخوردار است. اما آنچه در این نوشتار مدنظر است، شناسایی نوع قلم به دلیل مذکور نیست؛ کاربردی از آن می‌تواند در یک سیستم تحلیل صحنه یا یک سیستم حاسیه نویسی خودکار تصویر<sup>۴۲</sup> باشد. رسم الخطهای نستعلق، شکسته نستعلق

و ثلت از جمله‌ی مشهورترین‌ها در خوشنویسی فارسی هستند. رسم الخطهای نستعلق و شکسته نستعلق در تابلونگاره‌های خوشنویسی محبوبیت ویژه‌ای دارند؛ خط ثلت نیز در متون و کتبه‌های اماکن مذهبی جایگاه خاصی داشته و دارد. در این کاربرد با یک خزنده وب، با جستجوی عبارات «شکسته نستعلق» و «خطاطی ثلت» در گوگل، حدود هزار تصویر برداشت شد. با ملاحظه بصری، تعداد زیادی از نتایج نامطلوب حذف شدند<sup>۴۳</sup> و برای هر دسته ۳۵۵ تصویر لحاظ شدند. البته حذف تصاویر با کمی اغماض انجام شد. مثلاً تعداد معددی از تصاویر شکسته نستعلق به واقع جزو این خط محسوب نمی‌شند - مثلاً نستعلق بودند - اما از دیدگاه کلی شبیه به این خط بودند. برخی تابلوها دارای تصاویر پیش‌زمینه یا انسان هم بودند که اگر نوشتۀ مربوطه، بخش اصلی تصویر را تشکیل می‌داد حذف نشدند. نمونه‌هایی از تصاویر باقیمانده در شکل ۵ قابل مشاهده هستند. حجم کل تصاویر ۷.۵ مگابایت است. تصاویر به سه دسته‌ی آموزش، اعتبارسنجی و آزمون تقسیم شدند. از مجموع ۷۱۰ تصویر ۸۰ درصد (۵۶۸ تصویر) به عنوان

محتمم، جزو دسته‌ی شکسته علامت خورده‌اند که نمایانگر عملکرد مناسب شبکه است.



شکل ۹: خروجی بر روی تصویری شامل هر دو نوع رسم الخط. (الف) تصویر ورودی، (ب) نقشه رنگ حاصل از اعمال شبکه‌ی تمام پیچشی بر روی تصویر ورودی؛ نواحی تیره رنگ مشخص کننده مکان‌هایی از تصویر هستند که شبکه آنها را متعلق به گروه شکسته نستعلیق دسته‌بندی کرده است و نواحی روشن، به عنوان کتبه‌های خط ثلث دسته‌بندی شده‌اند. (ج) نگاشت نقشه رنگ بر روی تصویر ورودی؛ تا حدود زیادی نواحی هر دو نوع رسم الخط به درستی شناسایی شده‌اند. در این بخش یک شبکه‌ی پیچشی-چگال با دقت نزدیک به ۹۰ درصد برای طبقه‌بندی تابلوگاره‌های خوشنویسی فارسی به دو کلاس شکسته نستعلیق و ثلث طراحی و آموزش داده شد. با کپی کردن وزنه‌ای این شبکه‌ی آموزش دیده به یک شبکه‌ی عمیق تمام پیچشی معادل آن، شبکه جدید قابلیت کار بر روی تصاویر ورودی با اندازه‌هایی متفاوت از اندازه تصاویر مربعی آموزشی را پیدا کرده است. کاربرد این تبدیل در شکل ۹ ملاحظه گردید.

**۳ - ۲ - شناسایی برگ‌های سالم و بیمار با مدل پیچشی**  
کاربرد دیگری از روش پیشنهادی که در این بخش مورد بررسی قرار می‌گیرد، شناسایی برگ‌های سالم از برگ‌های با بیماری «پوسیدگی سیاه»<sup>۳۲</sup> درخت سیب است. تحقیقات متعددی در این زمینه انجام شده که در بسیاری از کارهای اخیر از یادگیری عمیق برای این مسئله استفاده شده است.<sup>[۲۰، ۲۱]</sup> در این تحقیقات، عموماً با استفاده از روش انتقال یادگیری<sup>۳۳</sup> یک مدل معروف از قبل آموزش دیده انتخاب شده و بر روی یک مجموعه آموزشی از برگ‌های سالم و مریض آموزش داده شده است. عموم این شیوه‌ها مبنی بر یک مدل پیچشی-چگال هستند که بر روی تصاویر برگ‌های مجزا آموزش دیده و قابلیت کارکرد و شناسایی بر روی تصویر یک برگ را دارند. با شیوه‌ی پیشنهادی در این نوشتار می‌توان یک مدل

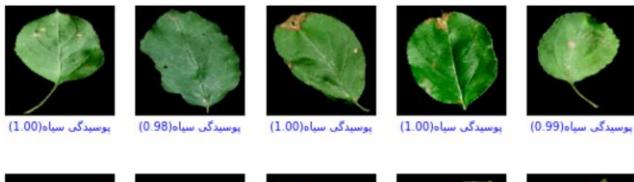
مربوط به رسم الخط شکسته، کلاس صفر (منفی) و رسم الخط ثلث، کلاس یک (ثبت) در نظر گرفته شده بوده است.



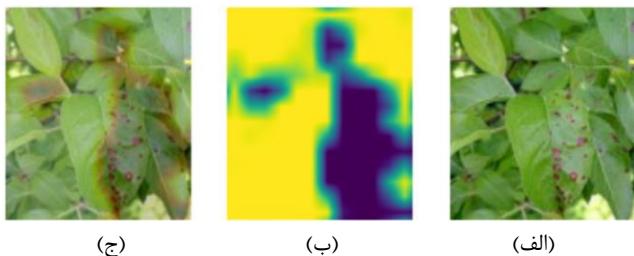
شکل ۸: خروجی روی ده تصویر آزمون. تصاویر آخر و اول از دو سطر اول و دوم، (با برچسب قرمز) به اشتباه طبقه‌بندی شده‌اند. مقادیر اعشاری میزان اطمینان هر مورد را نشان می‌دهد.

شکل ۸ نتیجه‌ی اجرای برنامه‌ی پایتون نوشته شده روی ده تصویر آزمون را نشان می‌دهد. سطر اول نمونه‌های شکسته نستعلیق (شکسته) هستند که همه به جز آخری به درستی تشخیص داده شده‌اند. سطر دوم نمونه‌های متعلق به رسم الخط ثلث هستند که اولی به اشتباه «شکسته» برچسب خورده است. مقادیر اعشاری میزان اطمینان هر مورد را نشان می‌دهد که همان خروجی آخرین لایه پیچشی است. از آنجا که فقط یک نورون در آخرین لایه پیچشی داشته‌ایم، خروجی شبکه عددی بین صفر تا یک بوده است. همین عدد برای کلاس یک در شکل فوق درج شده و یک منهای خروجی، به عنوان ضریب اطمینان مربوط به کلاس صفر نمایش داده شده است. با کپی کردن پارامترهای مدل پیچشی-چگال به مدل تمام پیچشی شکل ۳، مدل قابلیت عمل بر روی ورودی‌های با اندازه‌هایی فراتر از اندازه اولیه  $150 \times 150$  را پیدا می‌کند. شکل ۹ (الف) یک کتبه‌ی مربوط به شعر محتمم کاشانی با مطلع «باز این چه شورش است که در خلق عالم است» را نشان می‌دهد که با رسم الخط نستعلیق نگارش شده و مابین ابیات محتمم، نوشته‌هایی با خط ثلث هم دیده می‌شود. شکل ۹ (ب) خروجی شبکه‌ی تمام-پیچشی حاصل از تبدیل مدل پیچشی-چگال به تمام پیچشی را در قالب یک نقشه‌ی رنگ نشان می‌دهد که نقاط تیره‌تر به معنی احتمال تعلق بیشتر به کلاس شکسته نستعلیق و نقاط روشن‌تر به منزله میزان تعلق بیشتر به کلاس ثلث است. شکل ۹ (ج) نگاشت این نقشه‌ی رنگ بر روی تصویر اولیه را نشان می‌دهد. همان‌گونه که دیده می‌شود نواحی مشابه با تابلوگاره‌های آموزشی در تصویر به خوبی مشخص شده‌اند. در این کتبه، ابیات محتمم کاشانی با خط نستعلیق هستند که به خط شکسته شبیه‌تر هستند تا ثلث. ابیات

عمومی<sup>۳۴</sup> استفاده خواهیم کرد که حجم کل آن حدود ۵ گیگابایت است. به منظور نمایش نحوه عمل فقط از بخش مربوط به نمونه برگ‌های سالم و بیمار درخت سیب (نوع پوسیدگی سیاه) استفاده خواهد شد.



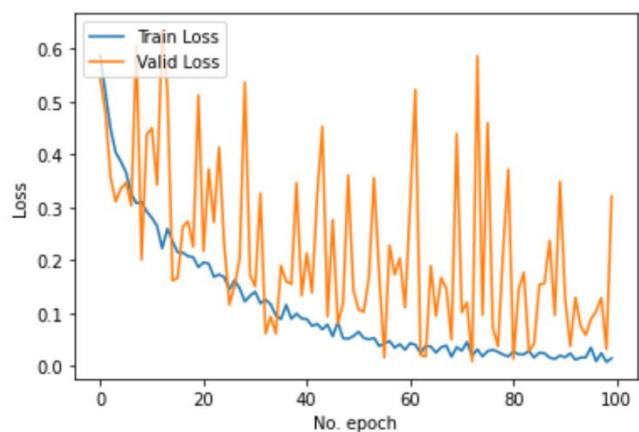
شکل ۱۲: خروجی روی ده تصویر آزمون. مقادیر اعشاری میزان اطمینان هر مورد را نشان می‌دهد.



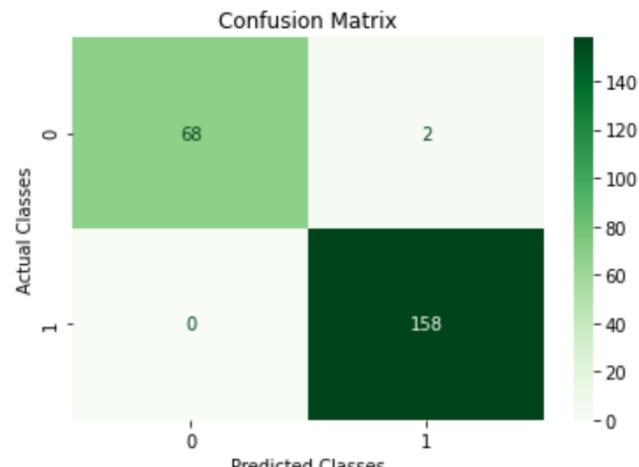
شکل ۱۳: خروجی بر روی تصویر شامل برگ‌های سالم و مریض. (الف) تصویر ورودی، (ب) نقشه رنگ حاصل از اعمال شبکه‌ی تمام پیچشی، نواحی آبی رنگ مشخص کننده‌ی مکان‌هایی از تصویر هستند که شبکه آنها را متعلق به گروه برگ‌های مریض دسته‌بندی کرده است و سایر نواحی مرتبط با برگ‌های سالم هستند. (ج) نگاشت نقشه رنگ بر روی تصویر ورودی. تا حدود زیادی نواحی مرتبط با برگ‌های مریض به درستی شناسایی شده‌اند.

زیر مجموعه‌ی مورد نظر در بخش دادگان گیت‌هاب این نوشتار قرار داده شده است. داده‌ها به سه گروه آموزش (۱۸۱۲ نمونه)، اعتبارسنجی (۲۲۶ نمونه) و آزمون (۲۲۸ نمونه) تقسیم شده‌اند. مشابه مثال بخش قبل، مدل بر روی داده‌های آموزشی، آموزش داده شد و مدل با کمترین خطا بر روی داده‌های اعتبارسنجی برای ادامه‌ی کار انتخاب گردید. شکل‌های ۱۰، ۱۱، ۱۲ و ۱۳ نمودار خطا روال آموزش، ماتریس درهم ریختگی و خروج مدل نهایی را نشان می‌دهند. دقت مدل بر روی داده‌های آزمون ۹۹٪ بوده است. با روش موربدبخت در این نوشتار، مدل پیچشی-چگال آموزش داده شده به یک مدل تمام پیچشی تبدیل می‌شود. شکل ۱۳ خروج مدل حاصله بر روی یک تصویر از برگ‌های یک درخت را نشان می‌دهد.<sup>۳۵</sup> اگر قرار باشد تصویر ۱۳(الف) به مدل معمول پیچشی-چگال، داده

اینچنینی مناسب را به یک مدل تمام پیچشی تبدیل کرد که قابلیت عمل بر روی تصاویری شامل مجموعه‌ای از برگ‌ها را داشته باشد.



شکل ۱۰: نمودار خطا (زیان) در ۱۰۰ تکرار روی داده‌ها. مدل با کمترین خطا بر روی مجموعه دادگان اعتبارسنجی، به عنوان بهترین مدل انتخاب می‌شود.



شکل ۱۱: ماتریس درهم ریختگی بر روی مجموعه دادگان آزمون در شناسایی برگ‌های مریض. در این اجرا میزان دقت ۹۹ درصد بوده است.

در اینجا هدف ایجاد یک مدل دقیق‌تر یا سریع‌تر از مدل‌های موجود نیست، لذا بحث مقایسه‌ی دقت یا سرعت مطرح نیست. نکته‌ی اصلی تغییر معماری مدل است که می‌تواند بر روی ورودی‌هایی با اندازه‌های متفاوت (شامل چندین برگ) کار کند. در این بخش از همان مدل بخش قبل (تفکیک تابلوونگاره‌های خط شکسته و ثلث) استفاده خواهیم کرد. برنامه‌ی مربوطه با نام FC2FC\_PlantDisease.ipynb در دسترس است. مجموعه دادگان مختلفی برای شناسایی امراض گیاهان موجود است. برای این کاربرد از یکی از این مجموعه دادگان

برتری از نظر دقت بر سایر روش‌ها نیست؛ هدف آن است که نشان داده شود چگونه یک شبکه عمیق مرسوم با لایه‌ی طبقه‌بند از نوع چگال چند کلاسه، به یک شبکه تمام پیچشی تبدیل شده و تصاویر ورودی با اندازه‌های مختلف را بپذیرد.

**جدول ۵: خلاصه مدل و پارامترهای مدل تمام پیچشی برای تصویر با اندازه ورودی  $135 \times 90\text{۲}$ .**

Layer (type)	Output Shape	Param #
Conv1: Conv2D(32,(3,3))	(None, 133, 900, 32)	320
MaxPool1: MaxPooling2D((2,2))	(None, 66, 450, 32)	0
Conv2: Conv2D(64,(3,3))	(None, 64, 448, 64)	18496
MaxPool2: MaxPooling2D((2,2))	(None, 32, 224, 64)	0
Conv3: Conv2D(128,(3,3))	(None, 30, 222, 128)	73856
MaxPool3: MaxPooling2D((2,2))	(None, 15, 111, 128)	0
lastConv: Conv2D(10,(1,1))	(None, 15, 111, 10)	1290
Total params:	93,962	

مشابه بخش پیش، ابتدا یک شبکه پیچشی عمیق معمول با لایه آخر طبقه‌بند ایجاد نموده و آموزش داده می‌شود. برای این کاربرد، یک شبکه با ۳ لایه پیچشی به ترتیب با تعداد ۳۲۴، ۶۴ و ۱۲۸ صافی که بعد از هر یک، یک لایه نمونه‌بردار قرار داده شده، تعریف شده است. پس از یک لایه مسطح ۱۲۸ تایی، در انتهای یک لایه چگال دهتایی عمل طبقه‌بندی را انجام می‌دهد. ۵۴۰۰۰ نمونه برای آموزش و اعتبارسنجی و ۶۰۰۰ نمونه برای تست انتخاب شدند. مدل ده اپک آموزش داده شد. دقت مدل بر روی داده‌های آزمون ۹۷٪ بوده است. نمودار خطای روال آموزش و جزئیات کار در برنامه‌ی مربوطه در گیت‌هاب این نوشتار موجود است که از درج آنها صرف‌نظر می‌شود. نکته اصلی تبدیل مدل پیچشی-چگال به تمام پیچشی است. خلاصه مدل پیچشی-چگال و پارامترهای آن در جدول ۴ آمده است. مدل تمام پیچشی جدیدی براساس وزن‌های مدل آموزش دیده فوق و روش مذکور در بخش‌های قبل ایجاد می‌شود. مدل پیچشی-چگال آموزش داده شده با این مدل تمام پیچشی یکی هست، با این تفاوت که دومی با تغییر اندازه ورودی و بدون آموزش مجدد، قابلیت پذیرش ورودی‌های با اندازه‌های متفاوت را دارا می‌باشد. در ادامه نتیجه‌ی اجرای مدل بر روی تصویری از یک دست‌نوشته‌ی حاوی ارقام فارسی با ابعاد  $135 \times 90\text{۲}$  را خواهیم دید. مدل جدید تمام پیچشی متناسب با تصویر ورودی با اندازه‌ی  $135 \times 90\text{۲}$  در جدول ۵ آمده است. آخرین لایه پیچشی، بُعد آخر

شود اولاً باید هم اندازه با تصاویر آموزشی شود و در ثانی مدل مذکور، کل این تصویر را به عنوان یک نمونه مورد بررسی قرار می‌دهد؛ در حالی که هدف، بررسی کل این تصویر به عنوان یک نمونه نیست. هدف در بررسی این تصویر، مشخص کردن سالم یا مریض بودن برگهای موجود در تصویر است.

**جدول ۴: خلاصه مدل و پارامترهای مدل پیچشی-چگال برای تصویر مجموعه داده ارقام فارسی هدی با اندازه ورودی  $26 \times 26$ .**

Layer (type)	Output Shape	Param #
Conv1: Conv2D(32,(3,3))	(None, 24, 24, 32)	320
MaxPool1: MaxPooling2D((2,2))	(None, 12, 12, 32)	0
Conv2: Conv2D(64,(3,3))	(None, 10, 10, 64)	18496
MaxPool2: MaxPooling2D((2,2))	(None, 5, 5, 64)	0
Conv3: Conv2D(128,(3,3))	(None, 3, 3, 128)	73856
MaxPool3: MaxPooling2D((2,2))	(None, 1, 1, 128)	0
Flatten1 (Flatten)	(None, 128)	0
Dense1 (Dense)	(None, 10)	1290
Total params:	93,962	

در صورت استفاده از مدل‌های معمول پیچشی-چگال باید برگ‌های تصویر با روشی دیگر استخراج شده و به مدل داده شود. اما مدل تمام پیچشی می‌تواند روی هر تصویری با هر اندازه‌ای کار کند؛ با این فرض که اندازه‌ی برگ‌ها در تصویر در حدود اندازه‌ی آنها در تصاویر آموزشی باشد، مدل جدید می‌تواند نتایج خوبی را به دست دهد. در این مثال برگ‌های مریض گروه با برچسب صفر و برگ‌های سالم گروه یک بوده اند. تصویر ۱۳ (ب) خروج مدل تمام پیچشی را نشان می‌دهد. نواحی روشن‌تر تعلق بیشتری به گروه یک (برگ‌های سالم) و نواحی تیره‌تر تعلق بیشتری به گروه صفر (برگ‌های بیمار) دارند. نگاشت این نقشه بر روی تصویر اصلی در شکل ۱۳ (ج) نمایش داده شده است. همان‌گونه که ملاحظه می‌شود تا حدود زیادی نواحی تیره‌تر مشخص کننده‌ی برگ‌های بیمار هستند. از آنجا که در این تصویر برگ‌ها با زوایای مختلف بوده‌اند و تصاویر برای آموزش شبکه، تبدیل‌های خاص (همچون دوران و انعکاس) بر روی تصاویر آموزشی اعمال شده است.

### ۳ - ۳- طبقه‌بندی ارقام فارسی با مدل تمام پیچشی

مدل مورد استفاده در دو مثال قبل با آخرین لایه پیچشی با اندازه‌ی  $1 \times 1 \times 1$  فقط مناسب طبقه‌بند دو کلاسه است. در این بخش نحوه‌ی کار روی مجموعه دادگان ارقام فارسی هدی [۲۳] را خواهیم دید که دارای ده طبقه می‌باشد. هدف در اینجا نمایش

#### ۴- جمع بندی

یادگیری عمیق بستر بسیار مناسبی برای کاربردهای تشخیصی در حوزه‌ی بینایی ماشین فراهم کرده است. مدل‌های مرسوم یادگیری عمیق مبتنی بر چند لایه‌ی پیچشی (کانولوشنی) و در نهایت لایه‌های طبقه‌بند هستند. در این مقاله از این مدل‌های مرسوم با عنوان پیچشی-چگال نام برده شد. در این نوشتار نحوه‌ی تبدیل یک شبکه‌ی پیچشی-چگال که لایه‌ی طبقه‌بند آن فقط از یک لایه‌ی مسطح و یک لایه‌ی چگال تشکیل شده است، به شبکه‌ی تمام پیچشی با ذکر کاربردهایی بیان گردید. ابتدا مدل مرسوم پیچشی-چگال بر روی داده‌های آموزشی آموزش داده می‌شود. سپس یک مدل مشابه با مدل پیچشی-چگال که لایه‌ی طبقه‌بند کاملاً متصل آن با یک لایه‌ی پیچشی عوض شده است جایگزین می‌شود. مدل جدید تمام پیچشی با همان وزن‌های مدل پیچشی-چگال قادر به کار می‌باشد. شیوه‌ی عملی کپی وزن‌های مدل اول به مدل جدید در برنامه‌ی پایتون مرتب با این نوشتار به صورت منبع باز در دسترس قرار داده شده است. روش مورد بحث در این نوشتار می‌تواند به عنوان راهکاری برای استفاده از مجموعه داده‌های پیشین، در بستر یادگیری عمیق بکار برده شود. مجموعه داده‌های برچسب‌زده‌ی بسیاری موجود هستند که قابلیت استفاده از شبکه‌های جدید یادگیری عمیق را دارند، اما همچون روش‌های قدیمی‌تر حوزه‌ی شناسایی الگو، مدل آماده شده فقط امکان کار با ورودی‌های با اندازه‌ی ثابت (هم اندازه با نمونه‌های آموزشی) را دارد. از طرفی برخی از مدل‌های جدید حوزه‌ی یادگیری عمیق نیازمند داده‌های آموزشی هستند که ناحیه‌ی اشیاء هدف در آنها به صورت دستی علامت‌گذاری شده باشند؛ که در مجموعه دادگانی که در روش‌های قدیمی‌تر فراهم شده‌اند، عموماً علامت‌گذاری تک به تک اشیاء در هر تصویر انجام نشده است. با راهکار مورد بحث در این نوشتار به عنوان پلی به گذشته، می‌توان ضمن استفاده از مجموعه دادگان آموزشی و مدل‌های مرسوم، مدلی داشت که بر روی ورودی‌هایی با هر اندازه قابلیت عملکرد را داشته باشد و بتواند نواحی مرتبه با اشیاء هدف در تصویر ورودی را مشخص کند. در واقع این شیوه امکان استفاده از ابزارهای جدیدتر با داده‌ها و مدل‌های مرسوم گذشته را فراهم می‌کند. دست آوردهای اصلی این نوشتار به شرح زیرند:

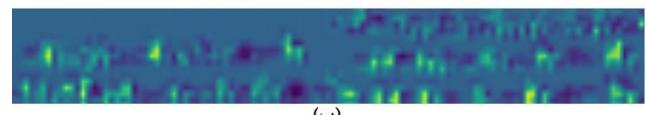
- بیان نحوه‌ی تبدیل شبکه‌های پیچشی-چگال به تمام پیچشی
- نمایش قابلیت استفاده از شبکه تبدیل شده با ورودی‌های با اندازه‌هایی فراتر از اندازه تصاویر آموزشی

برابر با ۱۰ دارد که متناظر با تعداد کلاس‌های مورد طبقه‌بندی است. شکل ۱۴ (الف) بخشی از یک برگه‌ی امتحان ریاضی پایه‌ی هفتم را نشان می‌دهد. اگر این تصویر به شبکه داده شود، در خروجی ۱۰ نقشه‌ی با ابعاد  $11 \times 15$  - متناظر با هر یک از ۱۵ رقم - خواهیم داشت.

۶- حاصل عبارت‌های زیر را به صورت تقریبی بدست آورید.

$$\begin{aligned} -71+59 &\approx -70+50 = -20 \\ -83-48 &\approx -10-40 = -50 \\ -41+37-82 &\approx -40+30-80 = -90 \\ 37-71 &\approx 30-70 = -40 \end{aligned}$$

(الف)



۷- حاصل عبارت‌های زیر را به صورت تقریبی بدست آورید.

$$\begin{aligned} -71+59 &\approx -70+50 = -20 \\ -83-48 &\approx -10-40 = -50 \\ -41+37-82 &\approx -40+30-80 = -90 \\ 37-71 &\approx 30-70 = -40 \end{aligned}$$

(ج)

شکل ۱۴: خروجی شناسایی نواحی مرتبط با رقم ۷ بر روی تصویری از یک برگه‌ی ریاضی هفتم. (الف) تصویر ورودی، (ب) نقشه رنگ حاصل از اعمال شبکه‌ی تمام پیچشی بر روی تصویر ورودی؛ نواحی روشن تر مشخص کننده‌ی مکان‌هایی از تصویر هستند که مطابق خروجی شبکه، در آنجا، به احتمال زیاد عدد ۷ وجود داشته است. (ج) نگاشت نقشه رنگ بر روی تصویر ورودی؛ تا حدود زیادی نواحی روشن تر مشخص کننده‌ی عدد ۷ هستند. عدمه نواحی روشنی که در آن ناحیه رقم ۷ در تصویر نیست، تا حدودی مشابه ۷ بوده‌اند، مانند عدد ۲.

شکل ۱۴ (ب) خروجی نقشه‌ی متناظر با رقم ۷ را نشان می‌دهد که نقاط روشن‌تر به معنی احتمال تعلق بیشتر به کلاس ۷ است. شکل ۱۴ (ج) نگاشت این نقشه‌ی رنگ بر روی تصویر اولیه را نشان می‌دهد. همان‌گونه که دیده می‌شود عدمه نواحی مرتبط با رقم ۷ به خوبی توسط مدل شناسایی شده‌اند. البته برخی نقاط، مانند عدد ۲ هم به اشتباه به عنوان ۷ شناسایی شده‌اند.

دو کاربرد اول، نمایش بهتری برای ایده‌ی این نوشتار بودند. در مواردی همچون شناسایی ارقام، بهتر است با استفاده از عملیات پیش‌پردازشی، هر کاراکتر استخراج شده و سپس ارقام شناسایی شوند. چنین پیش‌پردازشی برای تصویر اسناد متنی با افکش‌های عمودی و افقی تصویر به راحتی مقدور است، اما چنین شیوه‌ی سرراستی برای جداسازی نمونه‌های دو کاربرد اول در تصویر، موجود نیست و راه حل‌هایی به مانند روش پیشنهادی می‌تواند در چنین مسائلی راهگشا باشد.

- Transactions on Pattern Analysis and Machine Intelligence*, vol.39, no.6, pp.1137–1149, 2017.
- [7] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask RCNN," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.42, no.2, pp.386–397, 2020.
- [8] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.779–788, 2016.
- [9] J. Redmon and A. Farhadi, "Yolo9000: Better, faster, stronger," *CVPR*, 2017.
- [10] V. Badrinarayanan, A. Kendall, and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.39, no.12, pp.2481–2495, 2017.
- [11] N. Silberman, D. Hoiem, P. Kohli, and R. Fergus, "Indoor segmentation and support inference from RGBD images," in *Proceedings of the 12th European Conference on Computer Vision - Volume Part V, ECCV'12*, (Berlin, Heidelberg), p.746–760, Springer-Verlag, 2012.
- [12] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, "The Pascal Visual Object Classes (VOC) challenge," *International Journal of Computer Vision*, vol.88, pp.303–338, June 2010.
- [13] R. Mottaghi, X. Chen, X. Liu, N.-G. Cho, S.-W. Lee, S. Fidler, R. Urtasun, and A. Yuille, "The role of context for object detection and semantic segmentation in the wild," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2014.
- [14] T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and C. L. Zitnick, "Microsoft coco: Common objects in context," in *Computer Vision – ECCV 2014* (D. Fleet, T. Pajdla, B. Schiele, and T. Tuytelaars, eds.), (Cham), pp.740–755, Springer International Publishing, 2014.
- [15] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," in *International Conference on Learning Representations*, 2015.
- [16] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems 25* (F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, eds.), pp.1097–1105, Curran Associates, Inc., 2012.
- [۱۷] محمد صبری، محمد شهرام معین، و فربد رزا ذی، "روش پیشنهادی براساس یادگیری عمیق به منظور بهبود کارایی سیستم های تطبیق بیومتری مبتنی بر کارت هوشمند"، نشریه مهندس برق و مهندسی کامپیوتر، جلد ۱۸، شماره ۱-۲، صفحات ۴۱-۶۹، ۱۳۹۹.
- [18] X. Li, M. Kan, S. Shan, and X. Chen, "Weakly supervised object detection with segmentation collaboration," in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, October 2019.
- [19] S. Sheykhan, S. Meshgini, and Z. Mousavi, "Automatic detection of various epileptic seizures from eeg signal using deeplearningnetworks," *Computational Intelligence in Electrical Engineering*, vol.11, no.3, pp.1–12, 2020.
- [20] P. Jiang, Y. Chen, B. Liu, D. He, and C. Liang, "Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks," *IEEE Access*, vol.7, pp.59069–59080, 2019.
- [21] X. Chao, G. Sun, H. Zhao, M. Li, and D. He, "Identification of apple tree leaf diseases based on deep learning models," *Symmetry*, vol.12, p.17, 06 2020.
- [22] M. B. Tahir, M. A. Khan, K. Javed, S. Kadry, Y.-D. Zhang, T. Akram, and M. Nazir, "Recognition of apple leaf diseases using deep learning and variances-controlled features reduction," *Microprocessors and Microsystems*, p.104027, 2021.
- [23] H. Khosravi and E. Kabir, "Introducing a very large dataset of handwritten farsi digits and a study on their varieties," *Pattern Recognit. Lett.*, vol.28, pp.1133–1141, 2007.

- استفاده از مجموعه های آموزشی قدیمی در شبکه های پیچشی جدید
  - عدم نیاز به علامت گذاری اشیاء هدف در تصاویر
  - استفاده از شبکه های عصبی پیچشی برای طبقه بندی و شناسایی تابلو نگاره های دو رسم الخط فارسی
  - استفاده از روش پیشنهادی برای تفکیک برگ های بیمار از سالم در تصاویر دارای چندین برگ.
  - نمایش امکان تبدیل به مدل تمام پیچشی بر روی مسئله ای طبقه بندی و شناسایی ارقام فارسی به عنوان یک مسئله ای دارای چندین دسته.
- از جمله محدودیت های این شیوه می توان به موارد زیر اشاره کرد:
- هر مدل پیچشی-چگالی قابلیت تبدیل به تمام پیچشی را ندارد.
  - به جز امکان کار بر روی تصاویر ورودی با اندازه هی متغیر، هر محدودیتی که در مدل اولیه وجود داشته است، در مدل تبدیل شده هم خواهد بود. به عنوان نمونه اگر مدل اولیه، دوران یا تغییر مقیاس نمونه های ورودی را مورد لحاظ قرار نمی داده است، مدل تبدیل شده هم، همان گونه خواهد بود.
- روش پیشنهادی برای ایجاد یک مدل یادگیری عمیق از پایه، مناسب است و بسته به کاربرد، مدل نهایی می تواند بسیار کم حجم بوده و زمان آموزش زیادی لازم نداشته باشد. از آنجا که هدف این نوشتار افزایش دقت طبقه بند نبوده است، در خصوص کاربردهای ذکر شده، مقایسه ای با روش های قبل صورت نگرفته است؛ هر روش یادگیری عمیق مبتنی بر یک مدل پیچشی-چگال مناسب، با هر دقتی که وجود داشته باشد، با روش ذکر شده در این نوشتار، می تواند برای کاربردهای با اندازه هی ورودی متغیر به یک مدل تمام پیچشی تبدیل شود.

## مراجع

- [1] S. S. A. Zaidi, M. S. Ansari, A. Aslam, N. Kanwal, M. Asghar, and B. Lee, "A survey of modern deep learning based object detection models," *Digital Signal Processing*, vol. 126, p. 103514, 2022.
- [2] M. Schellenberg et al., "Semantic segmentation of multispectral photoacoustic images using deep learning," *Photoacoustics*, vol. 26, p. 100341, 2022.
- [3] E. Shelhamer, J. Long, and T. Darrell, "Fully convolutional networks for semantic segmentation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol.39, p.640–651, Apr. 2017.
- [4] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *2014 IEEE Conference on Computer Vision and Pattern Recognition*, pp.580–587, 2014.
- [5] R. Girshick, "Fast R-CNN," in *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*, ICCV '15, (USA), p.1440–1448, IEEE Computer Society, 2015.
- [6] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," *IEEE*

<sup>۱</sup>Convolutional Neural Networks (CNNs/ConvNets)

<sup>۲</sup>Annotated

<sup>۳</sup>[https://cs.nyu.edu/~silberman/datasets/nyu\\_depth\\_v2.html](https://cs.nyu.edu/~silberman/datasets/nyu_depth_v2.html)

<sup>۴</sup><https://github.com/shelhamer/fcn.berkeleyvision.org>

<sup>۵</sup><http://www.image-net.org/>

<sup>۶</sup>Pattern Analysis, Statistical Modelling and Computational Learning (PASCAL)

<sup>۷</sup>Visual Object Classes (VOC) <http://host.robots.ox.ac.uk/pascal/VOC/index.html>

<sup>۸</sup><https://cs.stanford.edu/~roozbeh/pascal-context/>

<sup>۹</sup><https://pjreddie.com/darknet/>

<sup>۱۰</sup>Weakly Supervised Object Detection (WSOD)

<sup>۱۱</sup>Build from scratch

<sup>۱۲</sup>Fully Connected or Dense

<sup>۱۳</sup>این کار در مسابقه شناسایی درختان ۲۷مین کنفرانس مهندسی برق ایران توسط نگارنده انجام شده است: <https://github.com/mamintoosi/tree-detection>

<sup>۱۴</sup>MaxPooling

<sup>۱۵</sup>Flatten

<sup>۱۶</sup>Dense

<sup>۱۷</sup>SoftMax

<sup>۱۸</sup>با اینکه لایه‌های تمام متصل و چگال (متراکم) یکی هستند، اما به لحاظ اینکه در صورت نامگذاری مدل به پیچشی-تمام متصل، با نوع شبکه تمام پیچشی اشتراک لفظ پیدا می‌کند، به نزدیک از عبارت «پیچشی-چگال» استفاده شد.

<sup>۱۹</sup>Fully Convolutional

<sup>۲۰</sup>ReLU

<sup>۲۱</sup>Keras, Tensorflow

<sup>۲۲</sup><https://github.com/mamintoosi/FC2FC>

<sup>۲۳</sup>به عنوان نمونه به تحقیقات احسان الله کبیر مراجعه شود:

<https://www.modares.ac.ir/~kabir>

<sup>۲۴</sup>Automatic image annotation

<sup>۲۵</sup>

نگارنده دارای مدرک خوش از انجمن خوشنویسان ایران می‌باشد.

<sup>۲۶</sup>end-to-end

<sup>۲۷</sup>Data Augmentation

<sup>۲۸</sup>Epoch

<sup>۲۹</sup>Batch Size

<sup>۳۰</sup>Loss

<sup>۳۱</sup>Accuracy

<sup>۳۲</sup>Apple Black rot

<sup>۳۳</sup>Transfer Learning

<sup>۳۴</sup>[https://github.com/digitalepidemiologylab/plantvillage\\_deeplearning\\_paper\\_dataset](https://github.com/digitalepidemiologylab/plantvillage_deeplearning_paper_dataset)

<sup>۳۵</sup>تصویر برگهای درخت از سایت دانشگاه ایالت میشیگان اخذ شده است:

[https://www.canr.msu.edu/ipm/diseases/black\\_rot\\_blossom\\_end\\_rot\\_frogeye\\_leaf\\_spot](https://www.canr.msu.edu/ipm/diseases/black_rot_blossom_end_rot_frogeye_leaf_spot)