

Detection of Slippery Road Conditions using the Road CCTV Images based on the Convolutional Neural Networks and Transfer Learning

M. A. Ghiahban, M. H. Shojaeifard, A. Amirkhani*

*Assistant Professor, Faculty of Mechanical Engineering, Iran University of Science and Technology, Tehran, Iran

(Received: 08/08/2021, Accepted: 06/02/2022)

ABSTRACT

The detection of slippery road conditions is one of the main factors needed in order to increase the road and passenger safety, as well as the development of autonomous vehicles and related technologies. In this regard, various researches have been done with different methods and sensors, using data in the different forms of image, sound and wave frequencies. In this article, we have detected the slippery road condition without the use of expensive sensors and methods by using CCTV images of the roads and based on convolutional neural networks. The main idea of this research is the use of transfer learning approach. Therefore, first, the importance and benefits of using transfer learning are presented in the form of network training with InceptionNetv3 architecture. In the next step, a ResNet50 CNN and a recurrent neural network are combined using a new framework called GFNet and are trained by using transfer learning. Finally, a tool with the ability to detect the road surface, in three classes of dry, wet and snow, has been obtained with an accuracy of 96.33%.

Keywords: Convolutional Neural Networks, Transfer Learning, Deep Learning, Road Safety, Classification.

* Corresponding Author Email: Amirkhani@just.ac.ir

تشخیص وضعیت لغزندگی جاده با استفاده از تصاویر دوربین‌های جاده‌ای مبتنی بر شبکه‌های

عصبی پیچشی و یادگیری انتقالی

محمدامین گیاهبان^۱، محمدحسن شجاعی فرد^۲، عبدالله امیرخانی^{۳*}

۱- کارشناس ارشد، ۲- استاد، دانشکده مهندسی مکانیک، ۳- استادیار، دانشکده مهندسی خودرو، دانشگاه علم و صنعت ایران، تهران، ایران

(دریافت: ۱۴۰۰/۰۵/۱۷، پذیرش: ۱۴۰۰/۱۱/۱۷)

چکیده

تشخیص وضعیت لغزندگی سطح جاده امری مهم در راستای افزایش امنیت جاده و سرنشینان و همچنین توسعه خودروهای خودران و فناوری‌های مرتبط با آن است. در این راستا پژوهش‌های مختلفی با روش‌ها و حسگرهای متفاوت، با استفاده از داده‌های گوناگونی نظیر تصویر، صوت و فرکانس موج صورت گرفته است. این مقاله بدون استفاده از حسگرها و روش‌های پرهزینه تنها با استفاده از تصاویر دوربین‌های مداربسته موجود در جاده‌ها و بهره‌گیری از شبکه‌های عصبی پیچشی انجام شده است. ایده اصلی پژوهش جاری استفاده از رویکرد یادگیری انتقالی است. بنابراین در ابتدا اهمیت و مزایای استفاده از یادگیری انتقالی، در قالب آموزش شبکه‌ای با ساختار InceptionNetv3 بیان شده است. در مرحله بعد با استفاده از چارچوبی جدید به نام GFNet، شبکه عصبی پیچشی ResNet50 و شبکه عصبی بازگشتی با یکدیگر ترکیب و با استفاده از یادگیری انتقالی آموزش داده شده‌اند. در نهایت شبکه‌ای با توانایی تشخیص سطح جاده، در سه دسته خشک، خیس و برفی با دقتی بالغ بر ۹۶٪ به دست آمده است.

کلیدواژه‌ها: شبکه‌های عصبی پیچشی، یادگیری انتقالی، یادگیری عمیق، امنیت جاده، طبقه‌بندی

۱- مقدمه

شده است.

از سویی دیگر جاده‌ها در طی زمان به دلایل گوناگون مانند شرایط مختلف آب و هوایی و استهلاک متحمل آسیب شده و تشخیص خرابی‌های موجود در جاده‌ها نیز نقشی مهم در امنیت وسیله نقلیه و سرنشینان ایفا می‌کند [۴]. پژوهش‌های متعددی در این زمینه انجام شده که غالباً با استفاده از تصاویر دوربین‌های مختلف و یادگیری عمیق^۷ صورت گرفته است [۵ و ۶]. در مواردی دیگر از رویکردهای یادگیری نیمه نظارتی نیز استفاده شده است [۷]. همچنین با استفاده از تصاویر دوربین‌های مختلف سامانه‌هایی نیز جهت تشخیص عابرین پیاده و اشیای مختلف نظیر ماشین‌ها و علائم راهنمایی طراحی شده‌اند [۸].

از دیگر کاربردهای اطلاعات جمع‌آوری شده، تشخیص وضعیت لغزندگی جاده‌ها است. آگاهی از شرایط لغزندگی جاده، به خصوص در مکان‌هایی مانند کشورمان که شرایط آب و هوایی چهار فصل را تجربه می‌کنند، تأثیر شگرفی در کاهش تصادفات دارد. همچنین این اطلاعات می‌تواند منجر به توسعه علائم هوشمند راهنمایی و رانندگی شود [۹]. در این مسئله نیز روش‌های گوناگون با استفاده از ابزارهای مختلف وجود داشته که

امروزه خودروهای مدرن با استفاده از ابزارهای مختلف نظیر رادار^۱، سونار^۲، لیدار^۳، مادون قرمز، موقعیت‌یاب‌ها^۴ و انواع دوربین‌ها اطلاعات زیادی از محیط اطراف خود به دست می‌آورند. استفاده از این اطلاعات و پیشرفت دانش در این حوزه سبب تولید فناوری‌هایی نظیر کروز کنترل، پارک خودکار، سامانه‌های جلوگیری از تصادف و خودروهای خودران شده است.

از این داده‌های جمع‌آوری شده برای موارد گوناگونی نظیر تشخیص خطوط جاده استفاده می‌شود. تشخیص خطوط جاده، موضوعی داغ در حیطه یادگیری ماشین^۵ و بینایی ماشین^۶ بوده که منجر به کاهش چشمگیر تصادفات و افزایش امنیت سرنشینان شده است [۱]. برخی پژوهش‌ها با استفاده از تصاویر دوربین‌های متصل به خودروها [۲] و در مواردی دیگر با استفاده از رویکردهای دوگانه نظیر ترکیب دوربین و لیدار [۳] انجام

* رایانامه نویسنده مسئول: Amirkhani@iust.ac.ir

¹ Radar

² Sonar

³ LIDAR

⁴ Global Positioning System (GPS)

⁵ Machine Learning

⁶ Machine Vision

⁷ Deep Learning



در [۱۰ و ۱۱] برخی از این روش‌ها و میزان کارایی آن‌ها با یکدیگر مقایسه شده‌اند.

در مجموع هدف اصلی این پژوهش‌ها و سامانه‌های مبتنی بر آن‌ها ایجاد تجربه‌ای امن‌تر و راحت‌تر برای راننده، سرنشینان و همچنین عابران پیاده است تا سبب افزایش ایمنی کلی حمل و نقل شوند [۱۲]. پیش‌تر ذکر شد از جمله موارد تأثیرگذار بر شرایط رانندگی و ایمنی، میزان لغزندگی سطوح جاده‌ها و خیابان‌ها است. به طوری که طبق پژوهش انجام‌شده در سال ۲۰۱۹، ۲۴/۱٪ از تصادفات ناشی از عدم هماهنگی سرعت خودرو با وضعیت لغزندگی سطح جاده بوده است [۱۳]. تصادفات خودروهای خودران در سال‌های اخیر نیز (به خصوص خودروهای تسلا) ناشی از ضعف این سامانه‌ها در تشخیص جاده، وضعیت آن و تنظیم متناسب حرکت خودرو بوده است [۱۴ و ۱۵].

افزایش تقاضای خودروهای خودران سبب ورود سازندگان مختلف به صنایع تولید آن‌ها شده است. این امر ناخواسته سبب ایجاد سامانه‌های گوناگون با سطوح دسترسی مختلف شده که افزایش خطر بالقوه نقص و خرابکاری را به همراه دارد [۱۶]. بنابراین استفاده از سامانه‌های بسته و متمرکز خارج از خودرو راه حلی معقول به نظر می‌رسد. برای مثال به جای استفاده از سامانه‌های داخل خودرو برای تشخیص لغزندگی جاده می‌توان با استفاده از تصاویر دوربین‌های جاده‌ای و ساخت علائم هوشمند راهنمایی و رانندگی و استفاده از سامانه‌های V2X^۱ خطر نقص و خرابکاری را کاهش داد [۱۷]. البته متمرکزسازی سامانه‌ها سبب افزایش احتمال حمله مرد میانی^۲ می‌شود اما با استفاده از رمزنگاری‌های پیشرفته امکان جلوگیری از این حمله‌ها وجود دارد [۱۸]. این در حالی است که امن کردن سامانه‌های غیر متمرکز گوناگون درون خودروهای مختلف امری پیچیده‌تر است.

یک سامانه تشخیص وضعیت لغزندگی مؤثر علاوه بر کمک به رانندگان برای مراجع نگهداری و تعمیرات راه‌ها نیز مفید است. به طوری که ابتدا مکان و زمان دقیق جاده‌ای که دچار لغزندگی شده را مشخص و سپس آن را به رانندگان و مراجع مربوطه ارجاع می‌دهد. در عین حال قیمت کم و سرعت بالا نیز حائز اهمیت است [۱۹].

وجود ابزارهای مختلف، داده‌های متنوع و روش‌های پردازش گوناگون سبب شده تا پژوهش‌های مختلفی در این زمینه صورت گیرد. تفاوت‌های عمده این روش‌ها در نوع داده‌ها (اعم از صوت یا تصویر)، نوع حسگرها و تجهیزات مورد نیاز، دقت در تشخیص و همچنین هزینه است. برخی از روش‌ها دارای محدودیت‌هایی

نظیر عدم کارایی در نور کم یا شب، عدم کارایی در آب و هوای بارانی هستند و همچنین برخی حسگرها نیاز به مکان اتصال خاصی دارند که این امر نیز منجر به محدودیت می‌شود [۲۰]. پژوهش‌های مبتنی بر تشخیص وضعیت سطوح جاده‌ها عموماً در سه دسته اصلی تشعشع امواج نور یا دما از سطح جاده، صدای ناشی از حرکت لاستیک روی سطح و تصویربرداری دسته‌بندی می‌شوند. برای مثال در پژوهشی [۲۱] گروهی از محققان حدود ۲۰۱۶ صوت ۵ min از حرکت لاستیک خودرو روی سطوح متفاوت در شرایط جوی مختلف را جمع‌آوری کردند. سپس با استفاده از روش‌های پردازش سیگنال، موفق به طبقه‌بندی شرایط جاده در چهار دسته خشک، خیس، گلی و برفی با دقت ۹۰٪ شدند. در این تحقیق از تحلیل صدا با استفاده از شبکه‌های عصبی بازگشتی^۳ دارای حافظه طولانی کوتاه‌مدت^۴، برای طبقه‌بندی استفاده شده است. پژوهشی دیگر [۲۲] نیز بر مبنای شبکه‌های عصبی بازگشتی دارای حافظه طولانی کوتاه‌مدت بنا شده است اما داده‌های ورودی سامانه از یک حسگر هوشمند متصل به لاستیک جمع‌آوری گشته است. محققانی دیگر همین موضوع را با استفاده از لیزر و تفاوت طول موج‌های ۱۳۲۳ nm و ۱۵۶۶ nm بر خاسته از سطح آسفالت پیگیری کرده و سطوح جاده را در چهار گروه خشک، خیس، یخی و برفی طبقه‌بندی کرده‌اند [۲۳]. تحقیقی دیگر نشان داد که با استفاده از یک جفت رادار ۲۴ GHz و ۷۷ GHz می‌توان آب یا یخ موجود در آسفالت را شناسایی کرد، چرا که وجود این دو ماده در آسفالت خواص مکانیکی آن را تغییر می‌دهد [۲۴]. در پژوهشی دیگر با اتخاذ رویکردی ترکیبی استفاده از دو حسگر رادار ۲۴ GHz و سونار ۴۰ KHz، با جمع‌آوری موج‌های منعکس شده از سطح جاده و استفاده از شبکه عصبی چندلایه^۵، به دقتی نزدیک به ۹۵٪ در طبقه‌بندی به خشک، خیس و برفی دست یافته‌اند [۱۲].

در سال ۲۰۱۱ جانسون [۲۵] پژوهشی در رابطه با طبقه‌بندی به خشک، خیس، برفی و یخ زده انجام داده است. وی در این پژوهش از حسگرهای مادون قرمز نزدیک^۶ استفاده کرده است. پیش‌تر در مواردی نیز برای توسعه ماشین‌های هوشمند از دوربین‌های استریو نیز استفاده شده است [۲۶]. شکل (۱) برخی ابزار جمع‌آوری داده را نشان می‌دهد. مشکل اصلی روش‌های مبتنی بر انعکاس نور یا صوت، تفاوت و گوناگونی داده‌های مختلف جمع‌آوری شده از سطوح مختلف با سختی‌های متفاوت است [۲۷]. همچنین شرایط محیطی می‌تواند منجر به خطای تجمیع شده گردد. از همین رو استفاده از روش‌های مبتنی بر

^۳ Recurrent Neural Network (RNN)

^۴ Long Short-Term Memory (LSTM)

^۵ Multi-Layer Perceptron Neural Network

^۶ Near Infrared (NIR) Sensors

^۱ Vehicle-to-everything (V2X)

^۲ Man In The Middle (MITM) Attack

مشخص شد این امر با استفاده از تصاویر به‌عنوان داده‌های ورودی قابل دست‌یابی است. بنابراین در این پژوهش از تصاویر دوربین‌های مداربسته جاده‌ها و راه‌ها به‌عنوان داده‌های ورودی بهره برده‌ایم. به‌طور کلی می‌توان نوآوری‌های صورت گرفته در این مقاله را به‌صورت زیر بیان کرد:

- (۱) بهره‌گیری از روش BRISQUE به‌عنوان بلوک پیش‌پردازش تصاویر؛
- (۲) استفاده از روش‌های یادگیری عمیق انتقالی برای طبقه‌بندی به جای روش‌های سنتی و آموزش از صفر و
- (۳) استفاده از چارچوب GFNet به‌منظور کاهش حجم محاسبات و افزایش دقت [۲۹].

در پژوهش جاری ابتدا به مبانی نظریه یادگیری انتقالی پرداخته می‌شود و شبکه‌ای را بر آن اساس آموزش داده می‌شود. سپس توضیحاتی در مورد رویکرد جدید اتخاذ شده و استفاده از GFNet^۴ داده و در مرحله بعد به تشریح شرایط مسئله جاری، پایگاه داده^۵ و چالش‌های آن پرداخته شده است. در نهایت شبکه با مشخصات مذکور آموزش داده شده و نتایج آن آورده شده است.

۲- رویکرد حل مسئله

پیش‌تر ذکر شد که در پژوهش جاری ورودی‌های سامانه تصاویر دوربین‌های مداربسته است و به‌تبع بهترین نحوه استفاده از این تصاویر در غالب شبکه‌های عصبی پیچشی است. در این مسیر روش‌های متفاوتی برای پیاده‌سازی شبکه عصبی و رسیدن به نتیجه مطلوب وجود دارد. در اینجا از روش یادگیری انتقالی در حالت معمول و همچنین با استفاده از چارچوب GFNet بهره گرفته شده است.

۲-۱- یادگیری انتقالی

یادگیری انتقالی به معنی استفاده از مدل‌های پیش‌تر آموزش داده شده و تغییر کاربری آن‌ها برای وظیفه جدیدشان است. به عبارت دیگر انتقال یاد گرفته‌های شبکه برای وظیفه‌ای جدید. در شبکه‌های عصبی پیچشی، معمولاً لایه‌های اولیه ویژگی‌های سطح پایین^۶ از قبیل یافتن گوشه‌های تیز و قسمت‌های خمیده را استخراج می‌کنند و هر چه لایه‌ها به جلو می‌روند معناگرایی در آن‌ها قوت بخشیده می‌شود. نکته مهم در این قسمت لزوم عظیم بودن پایگاه داده در مدل از قبیل آموزش دیده است، تا بتوان به

تصاویر از اهمیت بیشتری برخوردار هستند، از طرفی مزیت نسبی استفاده از روش‌های مبتنی بر تصاویر، در دسترس بودن تجهیزات و عدم نیاز به صرف هزینه‌های گزاف است. یکی از بهترین ابزارها برای پردازش تصاویر، شبکه‌های عصبی است. ابداع شبکه‌های عصبی و پیاده‌سازی آن در مسائل مختلف موجب پیشرفت شگرفی در حیطه یادگیری ماشین و مباحث مرتبط با آن شده است.



شکل (۱): حسگرها و ابزارهای مختلف جمع‌آوری اطلاعات از جاده‌ها (بالا لیدار، پایین دوربین استریو)

استفاده از شبکه‌های عصبی در بحث بینایی ماشین و پردازش تصویر منجر به شکل‌گیری نوعی جدید از شبکه‌های عصبی به نام شبکه‌های عصبی پیچشی^۱ شد. عمده کاربرد این شبکه‌ها در بحث‌های مرتبط با پردازش تصاویر است. شبکه‌های عصبی پیچشی متشکل از لایه‌های مختلفی هستند که هر لایه وابسته به موقعیت آن در شبکه و ساختار کلی شبکه، ویژگی‌هایی از تصویر ورودی را تشخیص می‌دهد و در نهایت با استنتاج از این ویژگی‌ها می‌توان کارهایی نظیر طبقه‌بندی^۲، قطعه‌بندی معنایی^۳ و ... را انجام داد. استفاده از شبکه‌های عصبی پیچشی در مسئله‌های طبقه‌بندی مختلف به خصوص در خودروهای خودران غالباً موفقیت‌آمیز بوده است. نکته حائز اهمیت در به‌کارگیری آن‌ها لزوم پراکندگی، کمیت و کیفیت مناسب داده‌های آموزش است [۲۸]. هدف اصلی ما در این مقاله پدید آوردن شبکه‌ای سریع و دقیق و در عین حال ارزان برای تشخیص وضعیت لغزندگی جاده است و همان‌طور که با بررسی پژوهش‌های پیشین

^۴ Glimpse and Focus Network

^۵ Dataset

^۶ Low Level Feature

^۱ Convolutional Neural Network (CNN)

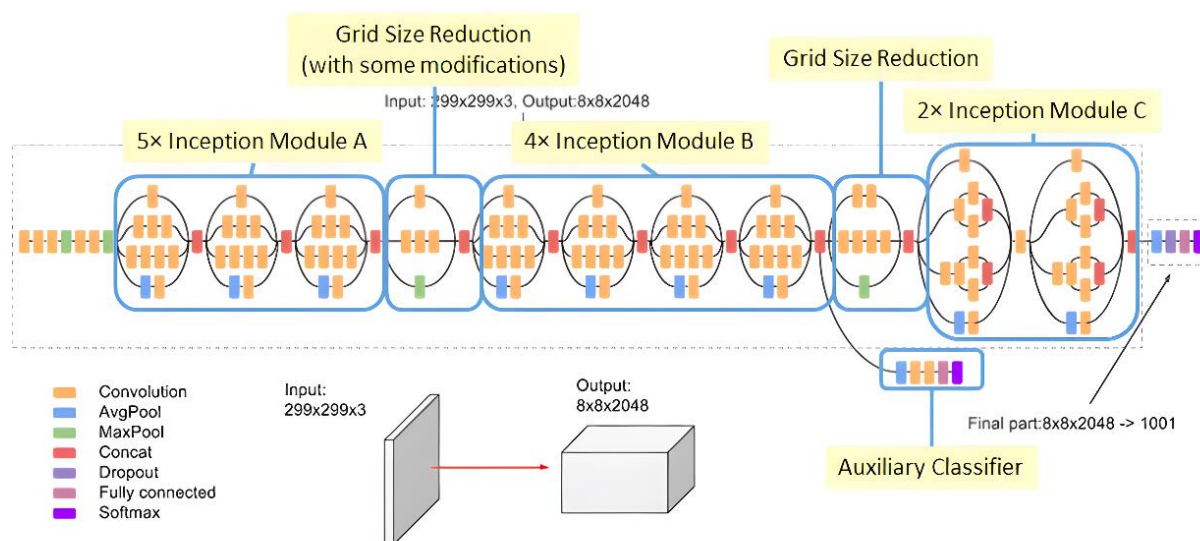
^۲ Classification

^۳ Semantic Segmentation

۲-۲-۱- ساختار InceptionNetv3

ساختار InceptionNet معروف به GoogleNet برای اولین بار توسط گوگل در سال ۲۰۱۵ معرفی شد [۳۰]. نسخه‌های دوم و سوم آن در سال ۲۰۱۶ جهت اصلاح ساختار و بهبود عملکردشان توسعه داده شدند [۳۱]. ایده اصلی شکل‌گیری این شبکه، ساخت شبکه‌ای عریض‌تر به جای شبکه‌ای صرفاً عمیق‌تر است. در شکل (۲) می‌توان ساختار InceptionNet نسخه سوم را مشاهده کرد [۳۲].

همان‌طور که در شکل (۲) مشخص است این شبکه دارای دو استنتاج‌گر است: اولی در انتهای شبکه و دومی در میانه. استنتاج‌گر اول اصلی^۱ و دوم کمکی^۲ نامیده شده است. هر دوی آن‌ها به صورت تماماً متصل^۳ هستند. بدیهی است در صورت استفاده از یادگیری انتقالی، باید هر دو استنتاج‌گر جایگزین شوند.



شکل (۲): ساختار شبکه InceptionNetv3 [۳۲]

افزایش یافته است.

در پژوهش ونگ، هدف اصلی کاهش هزینه محاسبات و افزایش سرعت استنتاج بدون کوچک کردن تصاویر بوده است. برای دستیابی به این موضوع ایده مطرح شده تکه‌تکه کردن عکس‌ها به قطعات کوچک‌تر و سعی در تشخیص دسته مرتبط با استفاده از تکه‌های کوچک‌تر است. این چارچوب در برخورد با هر عکس دو مرحله کلی زیر را انجام می‌دهد:

قابلیت تعمیم آن‌ها برای وظیفه جدید اعتماد کرد. برای دستیابی به این مهم معمولاً از مدل‌های آموزش دیده شده روی پایگاه‌های داده عظیم نظیر ImageNet با تعداد ۱۰۰۰ دسته استفاده می‌شود. این پایگاه داده بسیار متنوع بوده و به‌طور کلی متشکل از موارد مختلف با پراکندگی بالا نظیر توپ، رایانه، ماهی، مار، میز، ناخن و دیگر اشیاء است. در محث یادگیری انتقالی تفاوت دو پایگاه داده (پایگاه داده مدل آموزش دیده و پایگاه داده جدید) و البته حجم و پراکندگی پایگاه داده جدید بسیار حائز اهمیت است.

۲-۲-۲- یادگیری انتقالی با استفاده از InceptionNet

در وهله اول موارد ذکر شده در قسمت قبل در مورد یادگیری انتقالی به ساده‌ترین شکل ممکن و با استفاده از شبکه InceptionNetv3 انجام شده است و در گام بعدی این عمل در قالب چارچوب GFNet صورت گرفته است تا مزایای استفاده از این چارچوب ملموس‌تر باشد.

۳-۲-۳- یادگیری انتقالی با استفاده از چارچوب GFNet

ونگ و همکاران [۲۹] در سال ۲۰۲۰، چارچوبی به نام GFNet را معرفی کرده‌اند. ایده کلی این چارچوب کوچک‌تر کردن عکس‌های مورد استفاده جهت کم کردن هزینه محاسبات بوده زیرا به‌طور کلی رابطه‌ای مستقیم بین دقت شبکه‌ها و اندازه تصاویر ورودی برقرار است. با نگاه به برندگان چالش^۱ ILSVRC می‌توان دریافت که اندازه تصاویر در سال‌های مختلف رفته رفته

^۲ Main Classifier

^۳ Auxiliary Classifier

^۴ Fully Connected (FC)

^۱ ImageNet Large Scale Visual Recognition Challenge

ورودی تصویر x مدل به صورت مکرر تکه‌های $\{\tilde{x}_1, \tilde{x}_2, \dots\}$ را پردازش می‌کند. اولین تکه \tilde{x}_1 در حقیقت یک نسخه کامل ولی با وضوح پایین از x است که با رمزگذار سراسری پردازش می‌شود و تکه‌های بعدی $\{\tilde{x}_2, \tilde{x}_3, \dots\}$ تکه‌های با وضوح بالا هستند که توسط رمزگذار محلی تحلیل می‌شوند.

در هر مرحله GFNet با استفاده از طبقه‌بند f_c پیش‌بینی درباره دسته مد نظر قرار می‌دهد و همچنین موقعیت تکه بعدی را با کمک گرفتن از شبکه عصبی بازگشتی π انجام می‌دهد. در هر مرحله اگر اطمینان از طبقه‌بندی انجام شده به حد مطلوبی برسد فرآیند به پایان می‌رسد [۲۹].

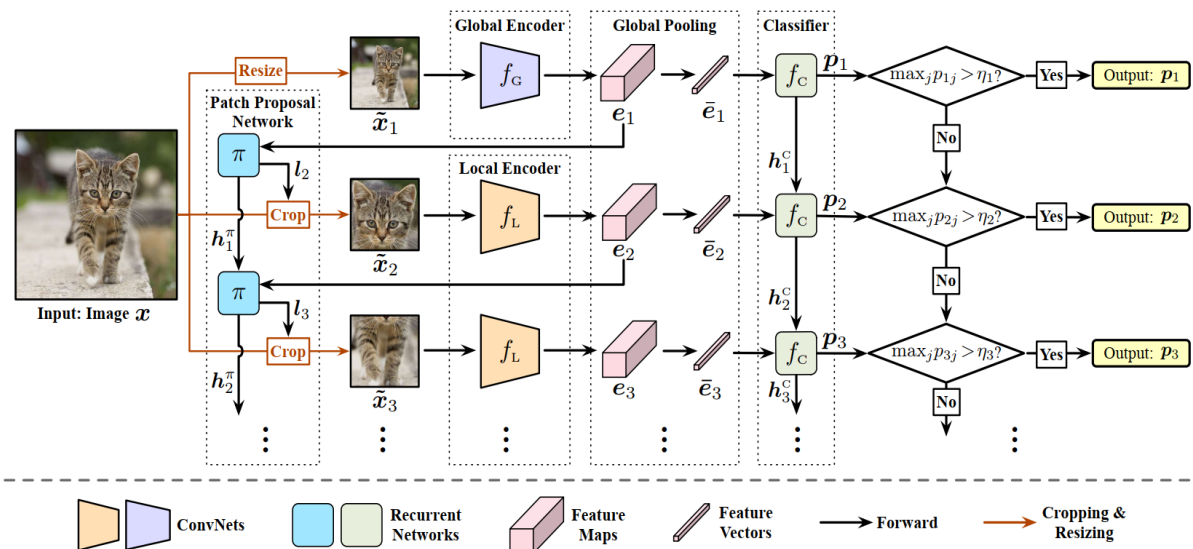
در پژوهش جاری برای دو رمزگذار فوق از ResNet50 استفاده شده است. اطلاعات بیشتر نظیر توابع هزینه^۶ و طبقه‌بندها و همچنین ساختار شبکه عصبی بازگشتی که وظیفه تکه کردن عکس‌ها را بر عهده دارد، در مرجع [۲۹] به‌طور کامل شرح داده شده است. لازم به ذکر است که متغیری جهت جلوگیری از بی‌نهایت شدن روند تکه کردن عکس، به‌عنوان حداکثر طول توالی ورودی^۷ برای استنتاج در نظر گرفته شده که در این پژوهش مقدار آن ۵ قرار داده شده است.

(۱) مرحله نگاه اجمالی^۱: در این مرحله عکس اصلی به صورت کوچک شده وارد شبکه می‌شود اگر شبکه بتواند با قطعیت خوبی دسته را تشخیص دهد کار استنتاج به پایان می‌رسد.

(۲) مرحله تمرکز^۲: در این مرحله شبکه بر اساس یاد گرفته‌هایش از داده‌های آموزش سعی می‌کند عکس را به تکه‌های مختلف کوچک‌تر تقسیم و هر قسمت را جداگانه بررسی کند، در صورتی که در هر تکه استنتاج با قطعیت خوبی رخ دهد شبکه از چرخه خارج می‌شود.

پیش‌تر ذکر شد که GFNet یک ساختار شبکه مستقل نیست و صرفاً یک چارچوب است که می‌تواند شبکه‌های عصبی پیچشی با ساختارهای مختلف را در دل خود به‌عنوان رمزگذار^۳ جای دهد.

شکل (۳) ساختار کلی این چارچوب را نمایش می‌دهد. می‌توان دریافت که درون این چارچوب علاوه بر شبکه‌های عصبی پیچشی، شبکه عصبی بازگشتی نیز وجود دارد تا توالی تکه کردن عکس‌ها و نتیجه‌گیری را ممکن سازد. از طرفی همان‌طور که در شکل مشخص است، دو رمزگذار در شبکه حضور دارد: رمزگذار سراسری^۴ و رمزگذار محلی^۵. رمزگذار سراسری برای مرحله نگاه اجمالی (تصویر کامل در اندازه کوچک‌تر) و رمزگذار محلی برای مرحله تمرکز مورد استفاده قرار می‌گیرد. بدین ترتیب که با فرض



شکل (۳): نمای کلی چارچوب GFNet [۲۹]

^۶ Cost Functions

^۷ Maximum Length of the Input Sequence


^۱ Glance Step

^۲ Focus Step

^۳ Encoder

^۴ Global Encoder

^۵ Local Encoder



شکل (۴): پراکندگی دسته‌های پایگاه داده

نمونه‌هایی از تصاویر ارزیابی شده در شکل (۵) قابل مشاهده است. با توجه به کیفیت پایین در برخی دسته‌ها و تعداد کم آن‌ها ۳ دسته اصلی خشک، خیس و برفی در نظر گرفته و ۱۰۰۰ عکس در هر دسته انتخاب شد. جهت جلوگیری از بیش‌برازش و از بین رفتن قابلیت تعمیم مدل، فیلترهایی برای داده افزایش^۳ نیز قرار داده شده است. نسبت داده‌های آموزش به داده‌های صحت‌سنجی ۷۰٪ به ۳۰٪ است و همچنین ۳۰۰ عکس متفاوت (۱۰۰ عدد در هر دسته) برای ارزیابی مدل در نظر گرفته شده است.



شکل (۵): نمونه‌هایی از تصاویر ارزیابی شده پایگاه داده در سه دسته خشک، خیس و برفی

۲-۳-۱- راهبرد آموزش در GFNet

آموزش در چارچوب GFNet از سه مرحله به شرح زیر تشکیل شده است:

مرحله اول: در این مرحله شبکه عصبی بازگشتی آموزش داده نمی‌شود و صرفاً عکس‌ها به‌طور تصادفی اما با توزیع یکنواخت تکه‌تکه می‌شوند. هدف از این مرحله تنها آموزش دو رمزگذار سراسری و محلی است.

مرحله دوم: در این مرحله دو رمزگذار دست نخورده باقی می‌مانند و صرفاً شبکه عصبی بازگشتی آموزش می‌بیند. هدف از این مرحله یافتن بهترین سیاست برای تکه کردن عکس‌ها است.

مرحله سوم: در مرحله آخر کل شبکه، دو رمزگذار و همچنین شبکه عصبی بازگشتی آموزش می‌بینند تا یک دقت مناسب برای مدل نهایی حاصل شود.

۳- پیاده‌سازی روند آموزش

در حال حاضر تصویری بزرگ از روند کلی حل مسئله ترسیم و اهداف مد نظر ذکر شده است. در این بخش با جزئیات بیشتر در رابطه با چگونگی آموزش، پایگاه داده و متغیرهای در نظر گرفته شده پرداخته می‌شود.

۳-۱- پایگاه داده

گربوسکی [۲۰] با جمع‌آوری تصاویر دوربین‌های ۲۷ ایستگاه در لهستان از نوامبر ۲۰۱۹ تا مارس ۲۰۲۰ پایگاه داده‌ای عظیم با بیش از ۳,۳۰۰,۰۰۰ عکس را تولید کرده است. این عکس‌ها در شرایط جوی و نوری متفاوت اعم از روز، گرگ‌ومیش و شب گرفته شده است. از طرفی این پایگاه داده شامل ۵ دسته کلی خشک، مرطوب، خیس، برفی و یخ زده است. همچنین علاوه بر دسته‌های مختلف، داده‌هایی نظیر سرعت و جهت باد، میزان شبنم و میزان رطوبت هوا نیز در این پایگاه داده وجود دارد.

به دلیل شرایط جوی و نوری مختلف برخی از عکس‌های پایگاه داده کیفیت خوبی ندارند بنابراین استفاده از یک روش ارزیابی تصاویر برای جدا کردن تصاویر مناسب از تصاویر نامناسب سبب بهبود دقت شبکه می‌شود. در حدود ۱۴۵۰۰۰ عکس از پایگاه داده فوق انتخاب شد که پراکندگی آن‌ها مطابق شکل (۴) است (لازم به ذکر است در پایگاه داده کامل نیز نسبت پراکندگی دسته برفی در قیاس با بقیه دسته‌ها بسیار پایین‌تر است). سپس با استفاده از نرم‌افزار متلب^۱، روش ارزیابی BRISQUE^۲ روی آن‌ها پیاده شد، طی این روش به هر عکس یک عدد اختصاص داده می‌شود به‌طوری که کیفیت عکس با عدد امتیاز آن رابطه عکس دارد [۳۳].

^۱ Matlab

^۲ Blind/Referenceless Image Quality Evaluator

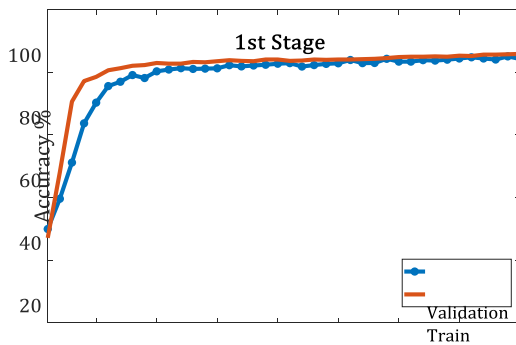
^۳ Data Augmentation

جدول (۱) متغیرهای آموزش مراحل مختلف را نشان می‌دهد.


جدول (۱): متغیرهای آموزش InceptionNet

۲۲۹	سایز تصاویر ورودی شبکه
۰/۰۰۰۵	نرخ یادگیری ^۳ مرحله اول
۰/۰۰۱	نرخ یادگیری مرحله دوم
۰/۰۰۱	نرخ یادگیری مرحله سوم
۰/۰۱	نرخ یادگیری مرحله چهارم
۰/۹	مقدار تکانه ^۴
۲۵۶	اندازه دسته ^۵

مطابق متغیرهای ذکر شده فرآیند آموزش انجام شده است. شکل (۶) میزان دقت آموزش و دقت صحت‌سنجی و شکل (۷) میزان زیان را در طی مرحله اول آموزش نشان می‌دهد.



شکل (۶): مرحله اول آموزش InceptionNet. درصد دقت



شکل (۷): مرحله اول آموزش InceptionNet. مقدار زیان

در این مقاله از Kaggle استفاده شده است. این محیط، پردازشگر گرافیکی Tesla P100 با ۳۵۸۴ هسته کودا، ۱۶ گیگابایت حافظه و توان پردازشی ۴/۷ ترافلاپس را در اختیار کاربر قرار می‌دهد. بالا بودن حافظه گرافیکی حائز اهمیت است زیرا چارچوب GFNet به دلیل پیچیدگی‌های آن در راستای آموزش دو شبکه عصبی پیچشی و بازگشتی به میزان بالایی از حافظه گرافیکی نیاز دارد.

۲-۳- آموزش InceptionNetv3 و نتایج

قبل تر ذکر شد که مبنای این پژوهش استفاده از روش یادگیری انتقالی است. به سبب تفاوت میان تعداد دسته‌های پایگاه داده مدل قبلی (ImageNet) و پایگاه داده فعلی حداقل یک مرحله تغییر استنتاج‌گرها و آموزش وزن‌های مربوط به آن‌ها الزامی است که این امر در مرحله اول انجام شده است. از طرفی دو پایگاه داده از نظر معنایی نیز تفاوت فاحشی دارند، بنابراین آموزش وزن‌های لایه‌های نهایی شبکه نیز امری منطقی خواهد بود که این امر به تدریج در مراحل دوم و سوم صورت گرفته است. در نهایت برای اینکه همه وزن‌های شبکه حداقل یک بار آموزش دیده باشند طی مرحله چهارم تمامی وزن‌ها آموزش داده شد. بنابراین ابتدا یک مدل از پیش آموزش دیده روی پایگاه داده ImageNet در نظر گرفته شده است و سپس در ۴ مرحله این مدل آموزش دیده تا به کاربری مد نظر این مقاله برسد. لازم به ذکر است که در تمامی مراحل الگوریتم آموزش، گرادینان نزولی تصادفی^۱ است. جزئیات چهار مرحله آموزش به شرح زیر است:

مرحله اول: در این مرحله تنها دو استنتاج‌گر شبکه تغییر یافته‌اند تا خروجی به جای ۱۰۰۰ دسته (تعداد دسته‌های پایگاه داده ImageNet) سه دسته خشک، خیس و برفی باشد. بعد از تغییر این دو، بقیه وزن‌های شبکه بدون تغییر و شبکه به تعداد ۴۰ ایپاک مورد آموزش قرار گرفته است. طی این مرحله نرخ یادگیری بسیار پایین فرض شده است.

مرحله دوم و سوم: طی این دو مرحله، علاوه بر وزن‌های دو استنتاج‌گر، قسمتی از وزن‌های شبکه هم آموزش داده شده است. شبکه در مرحله دوم ۵۰ ایپاک و مرحله سوم ۳۰ ایپاک آموزش دیده است. نرخ یادگیری در این دو مرحله یکسان بوده اما نسبت به مرحله اول افزایش یافته است.

مرحله چهارم: در نهایت طی آخرین مرحله از آموزش، کل وزن‌های شبکه در ۲۰ ایپاک آموزش دیده شده‌اند تا همبستگی وزن‌ها افزایش یابد و به اصطلاح تنظیم دقیق^۲ نهایی رخ دهد.

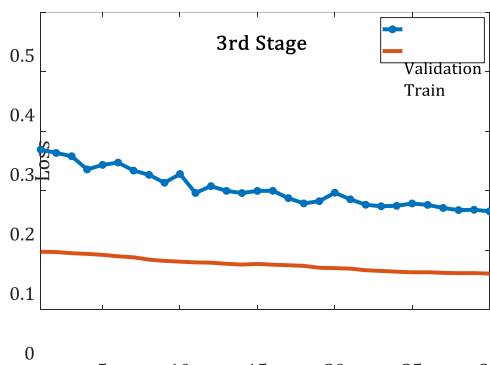
^۳ Learning Rate

^۴ Momentum

^۵ Batch Size

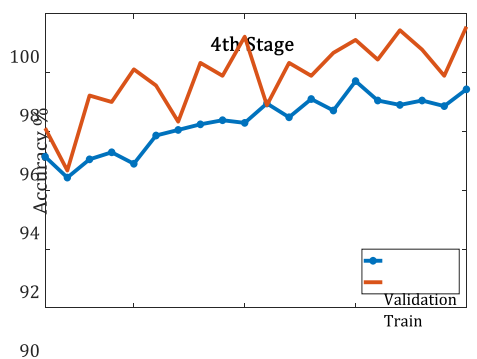
^۱ Stochastic Gradient Descent

^۲ Fine Tune




شکل (۱۱): مرحله سوم آموزش InceptionNet، مقدار زیان

همان‌طور که قابل مشاهده است با انجام مراحل دوم و سوم و آموزش وزن‌های مربوط به لایه‌های پیش‌بینی دقت صحت‌سنجی به بیش از ۹۰٪ رسیده است. حال برای ایجاد همبستگی بهتر بین وزن‌های آموزش دیده مرحله چهارم طی ۲۰ اپیاک انجام شده است، در این مرحله تمامی وزن‌ها آموزش دیده‌اند. شکل‌های (۱۲) و (۱۳) میزان دقت و زیان طی مرحله نهایی را نمایش می‌دهند.



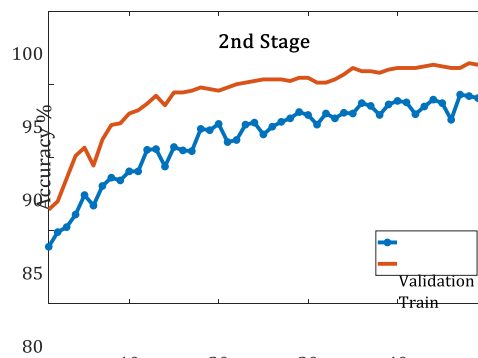
شکل (۱۲): مرحله چهارم آموزش InceptionNet، درصد دقت




شکل (۱۳): مرحله چهارم آموزش InceptionNet، مقدار زیان

با توجه به شکل‌های (۱۲) و (۱۳) می‌توان دریافت که انجام مرحله نهایی مقدار زیان و درصد دقت را به وضعیت مطلوب رسانده است. دقت آموزش به بیش از ۹۶٪ و دقت صحت‌سنجی

بدیهی است در مرحله اول میزان افزایش دقت به نسبت باقی مراحل زیاد است زیرا شبکه شروع به یادگیری وظیفه جدید خود می‌کند، اما میزان دقت به مقدار دلخواه افزایش نمی‌یابد. زیرا در این مرحله تنها دو استنتاج‌گر آموزش دیده‌اند و وزن‌های مربوط به لایه‌های پیش‌بینی ثابت می‌مانند. بعد از طی مرحله اول، مراحل دوم و سوم انجام شده است که نمودارهای مربوط به این دو مرحله در شکل‌های (۸ تا ۱۱) آورده شده است.

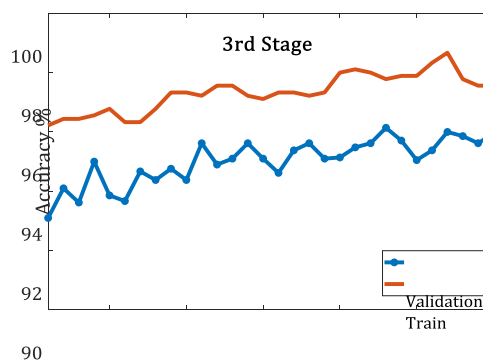


شکل (۸): مرحله دوم آموزش InceptionNet، درصد دقت

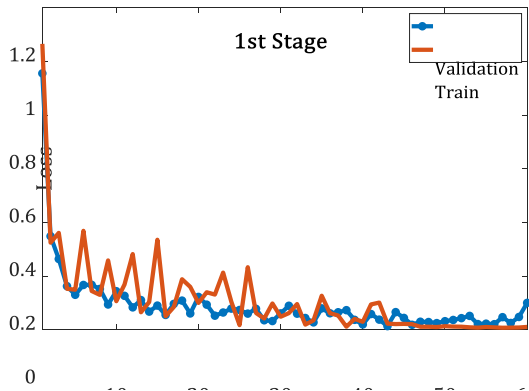


شکل (۹): مرحله دوم آموزش InceptionNet، مقدار زیان

در مرحله دوم حدود ۱۵٪ از وزن لایه‌های پیش‌بینی آموزش داده شده، این مقدار در مرحله سوم به ۳۰٪ افزایش پیدا کرده است.

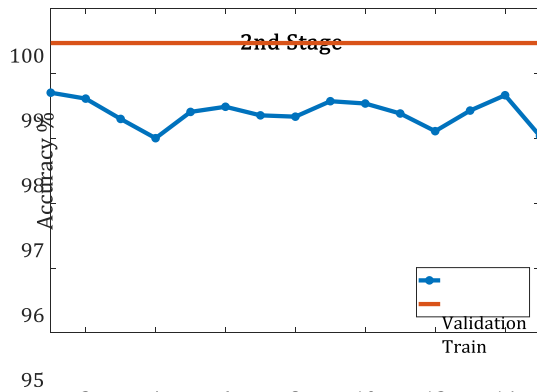


شکل (۱۰): مرحله سوم آموزش InceptionNet، درصد دقت

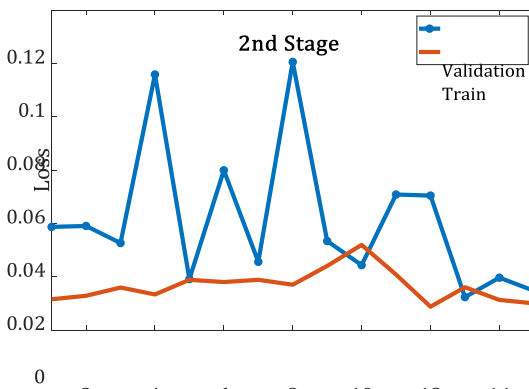


شکل (۱۵): مرحله اول آموزش GFNet، مقدار زیان

در مرحله دوم رمزگذارها و شبکه‌های عصبی پیچشی دست نخورده باقی مانده است و طی ۱۵ اپیاک شبکه عصبی بازگشتی و سیاست‌های انتخاب تکه‌ها بهینه شده‌اند. شکل‌های (۱۶ و ۱۷)، مقدار زیان و درصد دقت آموزش و صحت‌سنجی را در طول فرآیند مرحله دوم را نمایش می‌دهد.



شکل (۱۶): مرحله دوم آموزش GFNet، درصد دقت



شکل (۱۷): مرحله دوم آموزش GFNet، مقدار زیان

به بیش از ۹۴٪ رسیده است. در جدول (۲) خلاصه نتایج مربوط به کلیه مراحل آموزش این شبکه آورده شده است.

جدول (۲): نتایج دقت مراحل آموزش InceptionNetv3

مرحله	کمینه آموزش	بیشینه آموزش	کمینه صحت‌سنجی	بیشینه صحت‌سنجی
اول	٪۲۷/۱۱	٪۸۵/۸۹	٪۲۹/۹۵	٪۸۵/۱۰
دوم	٪۸۶/۴۴	٪۹۶/۴۴	٪۸۳/۹۰	٪۹۴/۲۹
سوم	٪۹۶/۲۲	٪۹۸/۶۷	٪۹۳/۱۰	٪۹۶/۱۴
چهارم	٪۹۴/۶۷	٪۹۹/۵۶	٪۹۴/۴۳	٪۹۷/۷۱

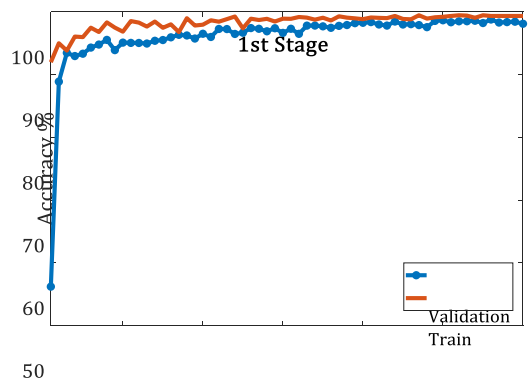
۳-۳- آموزش GFNet و نتایج

پیش‌تر ذکر شد که روند آموزش در چارچوب GFNet متشکل از سه مرحله است. جزئیات متغیرهای روند آموزش در جدول (۳) به شرح زیر آمده است:

در مرحله اول شبکه عصبی بازگشتی بدون تغییر باقی می‌ماند و رمزگذارها و شبکه‌های عصبی پیچشی آموزش می‌بینند. شکل‌های (۱۴ و ۱۵) درصد دقت و مقدار زیان مرحله اول را در طول ۶۰ اپیاک نشان می‌دهد.

جدول (۳): متغیرهای آموزش GFNet

۲۲۴	سایز تصاویر ورودی شبکه
۰/۰۱	نرخ یادگیری شبکه عصبی پیچشی (ResNet)
۰/۱	نرخ یادگیری شبکه عصبی کاملاً متصل در مرحله اول
۰/۰۱	نرخ یادگیری شبکه عصبی کاملاً متصل در مرحله سوم
۰/۹	مقدار تکانه
۶۴	اندازه دسته



شکل (۱۴): مرحله اول آموزش GFNet، درصد دقت

۴- ارزیابی و مقایسه نتایج

بعد از انجام مراحل آموزش حال با استفاده از ۳۰۰ تصویر ذکر شده (۱۰۰ عدد به ازای هر دسته) به ارزیابی مدل‌ها پرداخته شده است. میزان دقت مدل InceptionNetv3 برای پیش‌بینی تصاویر جدید به شرح جدول (۵) است.

با نگاه به نتایج فوق می‌توان دریافت مدل آموزش دیده از نظر تعمیم‌پذیری نیز قابل قبول بوده و به‌طور میانگین بیش از ۹۲٪ در ارزیابی موفق عمل کرده است.

جدول (۵): نتایج ارزیابی InceptionNetv3

دسته	کمینه دقت	بیشینه دقت	میانگین
خشک	٪۱/۱	٪۹۸/۵۹	٪۸۱/۶۷
خیس	٪۳/۱۵	٪۹۹/۹۸	٪۹۶/۳۱
برفی	٪۹/۱۶	٪۹۹/۹۹	٪۹۸/۷۹
میانگین			٪۹۲/۲۶

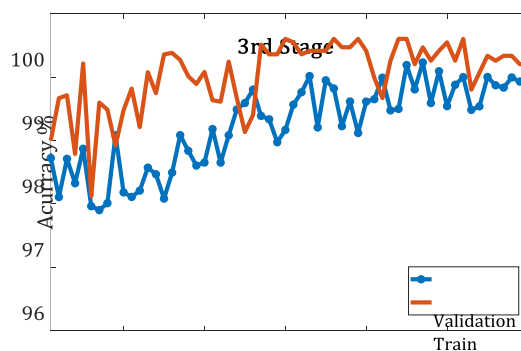
کمینه و بیشینه نتایج ارزیابی مدل GFNet نیز در جدول (۶) گزارش شده‌اند. لازم به ذکر است به دلیل کامل نبودن مدل مرحله اول (مشخص نبودن سیاست انتخاب تکه‌ها و وزن‌های شبکه عصبی بازگشتی) ارزیابی تنها در دو مرحله نهایی انجام شده است.

جدول (۶): درصد دقت در ارزیابی GFNet

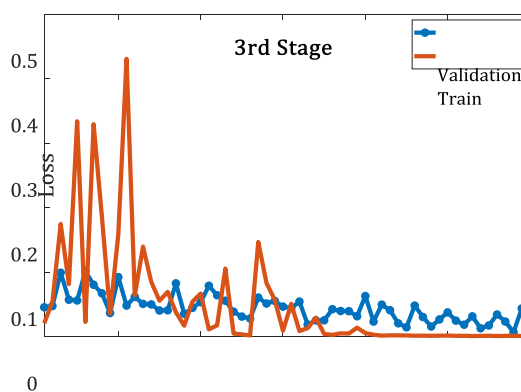
مرحله	کمینه درصد دقت	بیشینه درصد دقت
دوم	٪۹۲/۹۹	٪۹۴/۶۶
سوم	٪۹۵/۶۶	٪۹۶/۳۳

با مقایسه مراحل دوم و سوم می‌توان دریافت که با وجود اختیاری بودن مرحله سوم، انجام این مرحله تأثیر قابل توجهی در دقت نهایی شبکه دارد. افزایش دقت در مرحله سوم ناشی از همبستگی بهتر بین وزن‌های شبکه‌های عصبی پیچشی و رمزگذارها با وزن‌های شبکه عصبی بازگشتی است. از طرفی با مقایسه جدول‌های (۵) و (۶) می‌توان دریافت که کمینه دقت در GFNet افزایش یافته و همین امر سبب بالا رفتن میانگین دقت در GFNet و دست‌یابی به دقتی در حدود ۹۶٪ شده در حالی که این مقدار برای InceptionNetv3 برابر با ۹۲٪ است. حال می‌توان مقایسه‌ای بین روش‌های مختلف تعیین وضعیت لغزندگی جاده داشت. جدول (۷) به این مقایسه پرداخته است.

در نهایت طی مرحله سوم و نهایی شبکه‌های عصبی پیچشی، رمزگذارها و شبکه عصبی بازگشتی همگی آموزش دیده و وزن‌های آن‌ها به حالت بهینه می‌رسد. این مرحله حکم تنظیم دقیق^۱ نهایی را داشته و در ۶۰ اپیاک انجام شده است. نمودار جزئیات این مرحله در شکل‌های (۱۸) و (۱۹) آورده شده است.



شکل (۱۸): مرحله سوم آموزش GFNet، درصد دقت



شکل (۱۹): مرحله سوم آموزش GFNet، مقدار زیان

نتایج سه مرحله آموزش به‌صورت خلاصه در جدول (۴) آمده است.

جدول (۴): درصد دقت در مراحل آموزش GFNet

مرحله	کمینه آموزش	بیشینه آموزش	کمینه صحت‌سنجی	بیشینه صحت‌سنجی
اول	٪۹۱/۹۸	٪۹۹/۴۶	٪۵۶/۱۹	٪۹۸/۷۸
دوم	٪۹۹/۴۶	٪۹۹/۴۶	٪۹۸	٪۹۸/۷
سوم	٪۹۷/۱۱	٪۹۹/۶	٪۹۶/۹	٪۹۹/۲۳

^۱ Fine Tune

۷- مراجع

- [1] M. Li, Y. Li, and M. Jiang, "Lane Detection Based on Connection of Various Feature Extraction Methods," *Advances in Multimedia*, vol. 2018, pp. 1-13, 2018.
- [2] Y. Y. Ye, X. L. Hao, and H. J. Chen, "Lane Detection Method Based on Lane Structural Analysis and CNNs," *IET Intelligent Transport Systems*, vol. 12, no. 6, pp. 513-520, 2018.
- [3] L. Caltagirone, M. Bellone, L. Svensson, and M. Wahde, "LIDAR-camera Fusion for Road Detection Using Fully Convolutional Neural Networks," *Robotics and Autonomous Systems*, vol. 111, pp. 125-131, 2019.
- [4] B. Varona, A. Monteserin, and A. Teyseyre, "A Deep Learning Approach to Automatic Road Surface Monitoring and Pothole Detection," *Personal and Ubiquitous Computing*, vol. 24, no. 519-534, pp. 1-16, 2019.
- [5] R. Fan, M. J. Bocus, Y. Zhu, J. Jiao, L. Wang, F. Ma, S. Cheng, M. Liu., "Road Crack Detection Using Deep Convolutional Neural Network and Adaptive Thresholding," *IEEE Intelligent Vehicles Symposium (IV)*, IEEE, pp. 474-479, 2019.
- [6] M. D. Jenkins, T. A. Carr, M. I. Iglesias, T. Buggy, and G. Morison, "A Deep Convolutional Neural Network for Semantic Pixel-wise Segmentation of Road and Pavement Surface Cracks," *26th European Signal Processing Conference (EUSIPCO)*, IEEE, pp. 2120-2124, 2018.
- [7] C. Chun and S.-K. Ryu, "Road Surface Damage Detection Using Fully Convolutional Neural Networks and Semi-supervised Learning," *Sensors*, vol. 19, no. 24, p. 5501, 2019.
- [8] A. Khoshnavian, M. M. Tehrani, and A. Amirkhani, "Semantic Segmentation of Autonomous Vehicles Images with Teacher-Student Technique," *Journal of Electrical & Cyber Defence*, vol. 9, no. 4, pp. 1-19, 2021 (In Persian).
- [9] A. Czyżewski, A. Sroczynski, T. Śmiałkowski, and P. Hoffmann, "Development of Intelligent Road Signs with V2X Interface for Adaptive Traffic Controlling," *6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*, IEEE, pp. 1-7, 2019.
- [10] S. Roychowdhury, M. Zhao, A. Wallin, N. Ohlsson, and M. Jonasson, "Machine Learning Models for Road Surface and Friction Estimation Using Front-camera Images," *International Joint Conference on Neural Networks (IJCNN)*, IEEE, pp. 1-8, 2018.
- [11] G. Pan, L. Fu, R. Yu, and M. Muresan, "Evaluation of Alternative Pre-trained Convolutional Neural Networks for Winter Road Surface Condition Monitoring," *5th International*

جدول (۷): مقایسه روش‌های تشخیص لغزندگی جاده

دقت	داده‌های ورودی	روش/تجهیزات
٪۸۵	طول موج‌های منعکس شده	لیزر [۲۳]
٪۹۰	صدای حرکت لاستیک خودرو روی جاده	پردازش سیگنال [۲۱]
٪۹۵	انعکاس امواج از سطح جاده	رادار ۲۴ GHz و سونار ۴۰ KHz [۱۲]
٪۹۲/۲۶	تصاویر دوربین‌های جاده‌ای	یادگیری انتقالی در InceptionNetv3
٪۹۶	تصاویر دوربین‌های جاده‌ای	یادگیری انتقالی در GFNet

۵- نتیجه‌گیری

نتایج به‌دست آمده در این مقاله، نشان دهنده میانگین دقت مقادیر در مقایسه با پژوهش‌های بررسی شده نشان از پیشرفت دارد و بیانگر آن است که در تشخیص لغزندگی جاده، روش‌های مبتنی بر استفاده از تصاویر از دیگر روش‌ها مؤثرتر هستند. از طرفی بهترین ابزار برای استفاده از تصاویر شبکه‌های عصبی بوده در عین ارزان و در دسترس بودن بسیار کارآمد و مؤثر هستند. نکته حائز اهمیت در استفاده از تصاویر به‌عنوان داده ورودی یافتن روش‌های بهینه همانند GFNet است، به‌طور مثال طبق نتیجه پژوهش فعلی مشخص شد که GFNet با استفاده از شبکه‌ای ساده‌تر (ResNet50) در قیاس با شبکه پیچیده‌تر (InceptionNetv3) دقتی بالاتر را به‌دست آورده است، که دلیل این امر را می‌توان وجود شبکه بازگشتی در چارچوب GFNet و سیاست تکه کردن تصاویر به جای کوچک کردن آن دانست. به‌طور کلی استفاده از آموزش‌های مبتنی بر یادگیری انتقالی، کاهش زمان آموزش و دقت بالا را به ارمغان می‌آورد. از طرفی استفاده از GFNet در مسائل طبقه‌بندی نظیر این کار سبب کاهش چشمگیر حجم محاسبات و دستیابی به دقت بالا در زمانی کمتر می‌شود.

۶- پیشنهادات

در پژوهش‌های آتی می‌توان از ساختارهای دیگر به جای ResNet50 استفاده کرد و نتایج را مورد بررسی قرار داد. همچنین می‌توان با تغییر پایگاه داده یا ترکیب پایگاه داده‌های مختلف با یکدیگر، پایگاه داده‌ای با پراکندگی بیشتر ساخت. این امر می‌تواند خاصیت تعمیم‌پذیری مدل آموزش دیده را افزایش دهد که به بالا رفتن دقت نهایی منجر می‌شود.

- Polarised Light," In *Advanced Microsystems for Automotive Applications*, Springer, pp. 207-220, 2012.
- [24] V. Viikari, T. Varpula, and M. Kantanen, "Automotive Radar Technology for Detecting Road Conditions. Backscattering Properties of Dry, Wet, and Icy Asphalt," *European Radar Conference*, IEEE, pp. 276-279, 2008.
- [25] P. Jonsson, "Remote Sensor for Winter Road Surface Status Detection," *SENSORS, 2011 IEEE*, pp. 1285-1288, 2011.
- [26] Y. Kim, N. Baik, and J. Kim, "A Study on Development of Mobile Road Surface Condition Detection System Utilizing Probe Car," *Journal of emerging trends in computing and information sciences*, vol. 4, no. 10, pp. 742-750, 2013.
- [27] J. Alonso, J. M. López, I. Pavón, M. Recuero, C. Asensio, G. Arcas, A. Bravo, "On-board Wet Road Surface Identification Using Tyre/Road Noise and Support Vector Machines," *Applied acoustics*, vol. 76, pp. 407-415, 2014.
- [28] M. Nolte, N. Kister, and M. Maurer, "Assessment of Deep Convolutional Neural Networks for Road Surface Classification," *21st International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, pp. 381-386, 2018.
- [29] Y. Wang, K. Lv, R. Huang, S. Song, L. Yang, and G. Huang, "Glance and Focus: A Dynamic Approach to Reducing Spatial Redundancy in Image Classification," Presented at the NeurIPS, 2020.
- [30] S. P. Jakhar, A. Nandal, and R. Dixit, "Classification and Measuring Accuracy of Lenses Using Inception Model V3," In *Innovations in Computational Intelligence and Computer Vision*: Springer, pp. 376-383, 2021.
- [31] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818-2826, 2016.
- [32] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818-2826, 2016.
- [33] A. Mittal, A. K. Moorthy, and A. C. Bovik, "Blind/Referenceless Image Spatial Quality Evaluator," *Conference Record of the Forty Fifth Asilomar Conference on Signals, Systems and Computers (ASILOMAR) IEEE*, pp. 723-727, 2011.
- Conference on Transportation Information and Safety (ICTIS)*, IEEE, pp. 614-620, 2019.
- [12] A. Bystrov, E. Hoare, T.-Y. Tran, N. Clarke, M. Gashinova, and M. Cherniakov, "Automotive System for Remote Surface Classification," *Sensors*, vol. 17, no. 4, pp. 745, 2017.
- [13] M. Budzyński and A. Tubis, "Assessing the Effects of the Road Surface and Weather Conditions on Road Safety," *Journal of KONBiN*, vol. 49, no. 3, pp. 323-349, 2019.
- [14] E. Ackerman, "Fatal Tesla Self-driving Car Crash Reminds Us that Robots Aren't Perfect," *IEEE-Spectrum*, vol. 1, 2016.
- [15] M. R. Endsley, "Autonomous Driving Systems: A Preliminary Naturalistic Study of the Tesla Model S," *Journal of Cognitive Engineering and Decision Making*, vol. 11, no. 3, pp. 225-238, 2017.
- [16] A. Taeihagh and H. S. M. Lim, "Governing Autonomous Vehicles: Emerging Responses for Safety, Liability, Privacy, Cybersecurity, and Industry Risks," *Transport reviews*, vol. 39, no. 1, pp. 103-128, 2019.
- [17] A. Alnasser, H. Sun, and J. Jiang, "Cyber Security Challenges and Solutions for V2X Communications: A Survey," *Computer Networks*, vol. 151, pp. 52-67, 2019.
- [18] S. N. Doustimotlagh, "A New Framework for Enhancing the Security of Military Internet of Things Using the Hybrid Classical-Quantum Cryptography," *Journal of Electronical & Cyber Defence*, vol. 9, no. 2, pp. 29-49, 2021 (In Persian).
- [19] R. Robinson, "Slippery Road Detection and Evaluation," University of Michigan, Ann Arbor, Transportation Research Institute, 2012.
- [20] D. Grabowski and A. Czyżewski, "System for Monitoring Road Slippery Based on CCTV Cameras and Convolutional Neural Networks," *Journal of Intelligent Information Systems*, vol. 55, no. 3, pp. 521-534, 2020.
- [21] W. Kongrattanaprasert, H. Nomura, T. Kamakura, and K. Ueda, "Detection of Road Surface States from Tire Noise Using Neural Network Analysis," *IEEJ Transactions on Industry Applications*, vol. 130, no. 7, pp. 920-925, 2010.
- [22] D. Lee, J.-C. Kim, M. Kim, and H. Lee, "Intelligent Tire Sensor-Based Real-Time Road Surface Classification Using an Artificial Neural Network," *Sensors*, vol. 21, no. 9, p. 3233, 2021.
- [23] J. Casselgren, M. Kutila, and M. Jokela, "Slippery Road Detection by Using Different Methods of