

Vehicle Damage Detection After Accidents Using Deep Neural Networks: A Case Study in the Insurance Industry

Fatemeh Sarrami Foroushani ¹, | Hossein Mohammadi Dolat-abadi ^{2*} 

¹. M.Sc. in Industrial Engineering, Farabi Campus, University of Tehran fatemeh.sarrami@ut.ac.ir

². Corresponding Author: Faculty Member, Department of Industrial Engineering, Farabi College, University of Tehran
hmohammadi@ut.ac.ir

Article Info	ABSTRACT
Article type: Research Article	Objective: This study aims to investigate the capability of convolutional neural networks (CNNs) to identify and classify vehicle damage after accidents and to evaluate their potential application in the insurance industry.
Article history:	Necessity: Vehicle damage assessment in the insurance industry is generally time-consuming and requires expert inspection. The application of intelligent image-processing methods can facilitate preliminary damage assessment, reduce claim-processing time, and support the development of intelligent insurance systems.
Keywords: Deep Learning, Image Processing, Convolutional Neural Network, Vehicle Damage, Insurance Industry	Methodology: The research data consists of real images of damaged vehicles belonging to third-party insurance customers during 2020 and 2021. From approximately 20,000 images, 4,100 were selected to train and evaluate seven deep learning architectures: AlexNet, VGG-19, ResNet-50, ResNet-101, EfficientNetB7, EfficientNetV2L, and MobileNetV2. The models were evaluated for classifying six types of vehicle damage: superficial damage, severe damage, side-mirror damage, windshield damage, tire damage, and vehicle-light damage.
	Findings: The results showed that model performance in terms of speed and accuracy was influenced by the structure and characteristics of the pre-trained architecture. The classification accuracy of the evaluated models ranged from 59% to 63%. The findings also demonstrated the capability of deep convolutional neural networks to extract visual features and distinguish different types of vehicle damage.
	Conclusion: The findings indicate that convolutional neural networks and transfer learning methods have promising potential for the identification and preliminary assessment of vehicle damage after accidents. These models can provide a foundation for developing intelligent damage assessment systems in the insurance industry, helping to reduce assessment time, accelerate claim-processing procedures, and improve the efficiency of insurance processes.

تشخیص آسیب خودرو پس از تصادفات با استفاده از شبکه های عصبی عمیق:

یک مطالعه موردی در صنعت بیمه

فاطمه صرامی فروشانی^۱ حسین محمدی دولت آبادی^{۲*}

چکیده

هدف: بررسی قابلیت شبکه های عصبی پیچشی در شناسایی و طبقه بندی خسارت خودرو پس از تصادف در صنعت بیمه است..

روش شناسی: داده های پژوهش شامل تصاویر واقعی خودروهای آسیب دیده متعلق به مشتریان بیمه شخص ثالث در سال های ۱۳۹۹ و ۱۴۰۰ است. از میان حدود ۲۰ هزار تصویر، ۴۱۰۰ تصویر برای آموزش و ارزیابی هفت معماری شامل AlexNet، VGG-۱۹، ResNet-۵۰، ResNet-۱۰۱، EfficientNetB۷، MobileNetV۲ و EfficientNetV۲ انتخاب شد. مدل ها برای تشخیص شش نوع آسیب شامل آسیب سطحی، عمیق، آینه جانبی، شیشه، لاستیک و چراغ خودرو مورد بررسی قرار گرفتند.

یافته ها: نتایج نشان داد که عملکرد مدل ها از نظر سرعت و دقت، تا حد زیادی تحت تأثیر ساختار و ویژگی های معماری شبکه های از پیش آموزش دیده قرار دارد. دقت مدل های مورد بررسی در تشخیص و طبقه بندی انواع خسارت خودرو در بازه ۵۹ تا ۶۳ درصد قرار گرفت. مقایسه معماری های مختلف همچنین نشان داد که استفاده از شبکه های عصبی پیچشی عمیق می تواند قابلیت قابل قبولی در استخراج ویژگی های تصویری و تفکیک انواع آسیب های خودرو فراهم کند، هرچند عملکرد مدل ها به کیفیت و حجم داده های آموزشی و همچنین نوع معماری مورد استفاده وابسته است.

نتیجه گیری: نتایج پژوهش بیانگر ظرفیت شبکه های عصبی پیچشی و روش های انتقال یادگیری برای شناسایی و ارزیابی اولیه خسارت خودرو پس از تصادف است. استفاده از چنین مدل هایی می تواند به عنوان بستری برای توسعه سامانه های هوشمند ارزیابی خسارت در صنعت بیمه مورد توجه قرار گیرد و در صورت توسعه مجموعه داده، بهبود کیفیت تصاویر و بهینه سازی مدل ها، زمینه کاهش زمان ارزیابی، تسریع فرایند رسیدگی به خسارت و افزایش بهره وری فرایندهای بیمه ای را فراهم سازد.

کلیدواژه ها: یادگیری عمیق، پردازش تصویر، شبکه عصبی پیچشی، خسارت خودرو، صنعت بیمه

پذیرش مقاله: ۱۴۰۴/۰۶/۲۵....

دریافت مقاله: ۱۴۰۳/۱۲/۲۳

۱. کارشناسی ارشد مهندسی صنایع دانشکده گان فارابی دانشگاه تهران fatemeh.sarrami@ut.ac.ir۲. نویسنده مسئول: عضو هیئت علمی گروه مهندسی صنایع دانشکده گان فارابی دانشگاه تهران hmohammadi@ut.ac.ir

مقدمه

امروزه کسب و کارها در حوزه‌های مختلف، به‌طور فزاینده‌ای در پی بهینه‌سازی فعالیت‌ها و فرآیندهای خود با بهره‌گیری از فناوری‌های نوین، هوش مصنوعی و روش‌های داده‌محور هستند (LeCun et al., 2015; Goodfellow et al., 2016). هم‌زمان با گسترش فعالیت‌های تجاری و اقتصادی، صنعت بیمه و فرآیندهای مرتبط با آن، از جمله ارزیابی و برآورد خسارت، نیز به سمت استفاده گسترده‌تر از روش‌های هوشمند و خودکار حرکت کرده است. پیشرفت‌های اخیر در حوزه بینایی ماشین و یادگیری عمیق، به‌ویژه شبکه‌های عصبی پیچشی، امکان استخراج خودکار ویژگی‌ها و طبقه‌بندی تصاویر را با دقت قابل توجهی فراهم کرده است (Krizhevsky et al., 2012; He et al., 2016). این قابلیت موجب شده است روش‌های مبتنی بر یادگیری عمیق به‌عنوان ابزاری مناسب برای شناسایی و طبقه‌بندی آسیب‌های ظاهری خودرو و پشتیبانی از فرآیند ارزیابی خسارت مورد توجه قرار گیرند. در فرآیند رسیدگی به خسارت‌های ناشی از تصادفات خودرویی، ذی‌نفعان مختلفی از جمله مالکان خودرو، شرکت‌های بیمه، تعمیرگاه‌ها و ارائه‌دهندگان خدمات خودرویی حضور دارند که هریک اهداف و منافع متفاوتی را دنبال می‌کنند. مشتریان انتظار دارند با کمترین هزینه و در کوتاه‌ترین زمان، خدماتی دقیق و مناسب دریافت کنند؛ تعمیرگاه‌ها و ارائه‌دهندگان خدمات خودرویی نیز در چارچوب ضوابط و قراردادهای موجود در پی ارائه خدمات و تأمین منافع اقتصادی خود هستند. از سوی دیگر، شرکت‌های بیمه در مقابل دریافت حق بیمه، بخشی از ریسک مالی ناشی از وقوع حوادث را طبق شرایط قرارداد پوشش داده و در صورت تحقق خطر، خسارت یا خدمات مورد تعهد را ارائه می‌کنند. از این‌رو، فرآیند ارزیابی خسارت خودرو در نقطه تلاقی منافع چندین ذی‌نفع قرار دارد و دستیابی به یک ارزیابی سریع، دقیق و قابل اتکا از اهمیت ویژه‌ای برخوردار است.

در تعامل میان بازیگران مختلف این فرآیند، دو مسئله مهم شامل بروز رفتارهای متقابلانه و اختلاف‌نظر در ارزیابی خسارت قابل طرح است. در برخی موارد، انگیزه‌های اقتصادی می‌تواند زمینه بروز رفتارهایی نظیر تصادفات ساختگی، ارائه اطلاعات نادرست درباره میزان خسارت، تبانی با عوامل ارزیابی خسارت یا صدور صورت‌حساب‌های غیرواقعی را فراهم کند. تقلب در مطالبات بیمه‌ای یکی از چالش‌های شناخته‌شده صنعت بیمه است که علاوه بر افزایش هزینه‌های شرکت‌های بیمه، می‌تواند کارایی فرآیند رسیدگی به خسارت را نیز تحت تأثیر قرار دهد (Derrig, 2002). از سوی دیگر، در روش‌های سنتی، ارزیابی خسارت تا حد زیادی به دانش، تجربه و قضاوت کارشناسان وابسته است. بنابراین، تفاوت در سطح تخصص و قضاوت فردی کارشناسان می‌تواند به تفاوت در نتایج ارزیابی و شکل‌گیری اختلاف‌نظر میان مالکان خودرو، شرکت‌های بیمه و مراکز تعمیراتی منجر شود. چنین اختلافاتی ممکن است موجب افزایش مدت‌زمان رسیدگی به پرونده، نارضایتی مشتریان و افزایش هزینه‌های اجرایی شود. در نتیجه، توسعه روش‌هایی که بتوانند فرآیند ارزیابی خسارت را با سرعت، ثبات و عینیت بیشتری انجام دهند، از اهمیت قابل توجهی برخوردار است. در این راستا، بهره‌گیری از سامانه‌های هوشمند مبتنی بر پردازش تصویر و یادگیری عمیق می‌تواند به‌عنوان ابزاری برای پشتیبانی از فرآیند تشخیص و ارزیابی آسیب خودرو مورد استفاده قرار گیرد. شبکه‌های عصبی عمیق، به‌ویژه شبکه‌های عصبی پیچشی، توانایی بالایی در استخراج خودکار ویژگی‌ها و شناسایی الگوهای موجود در تصاویر دارند (LeCun et al., 2015; Goodfellow et al., 2016). همچنین، توسعه معماری‌های پیشرفته شبکه‌های عصبی پیچشی موجب بهبود قابل توجه عملکرد مدل‌های طبقه‌بندی و تشخیص تصویر شده است (Krizhevsky et al., 2012; He et al., 2016). استفاده از این روش‌ها می‌تواند زمینه کاهش وابستگی فرآیند تشخیص اولیه آسیب به ارزیابی کاملاً دستی و تسریع فرآیند رسیدگی به پرونده‌های خسارت را فراهم سازد. در این پژوهش، هفت مدل مبتنی بر شبکه‌های عصبی پیچشی عمیق با استفاده از رویکرد انتقال یادگیری و بر پایه هفت شبکه از پیش آموزش‌دیده، به‌منظور شناسایی

و طبقه بندی آسیب های خودرو پس از تصادف مورد ارزیابی قرار گرفته اند. برای این منظور، مجموعه داده ای شامل تصاویر واقعی خودروهای آسیب دیده تهیه و تصاویر بر اساس نوع خسارت در شش گروه شامل آسیب سطحی، آسیب عمیق، آسیب آینه جانبی، آسیب شیشه، آسیب لاستیک و آسیب چراغ خودرو دسته بندی شده اند. با توجه به تعداد متفاوت تصاویر موجود برای انواع خسارت، تعداد نمونه ها در گروه های مختلف یکسان نبوده است. داده های تهیه شده پس از آماده سازی، برای آموزش، اعتبارسنجی و آزمون مدل های پیشنهادی مورد استفاده قرار گرفته اند. در برخی تصاویر بیش از یک نوع آسیب به طور هم زمان مشاهده می شود. از این رو، برخی تصاویر متناسب با نوع آسیب موجود در بیش از یک گروه قرار گرفته اند و میزان این هم پوشانی حدود ۱۰ تا ۱۵ درصد از کل داده ها بوده است. این رویکرد با هدف پوشش بهتر شرایط واقعی و در نظر گرفتن تصاویر دارای چند نوع آسیب اتخاذ شده است. به منظور مقایسه عملکرد معماری های مختلف، هفت شبکه از پیش آموزش دیده و پرکاربرد شامل AlexNet، VGG-19، ResNet-50، ResNet-101، EfficientNetB7، EfficientNetV2L و MobileNetV2 انتخاب شدند. با بهره گیری از انتقال یادگیری، ویژگی های آموخته شده این شبکه ها به مسئله تشخیص آسیب خودرو منتقل شده و عملکرد مدل های حاصل بر اساس معیارهای ارزیابی مختلف با یکدیگر مقایسه شده است. هدف اصلی پژوهش حاضر، توسعه و ارزیابی رویکردی مبتنی بر یادگیری عمیق برای تشخیص خودکار انواع آسیب های خودرو با استفاده از تصاویر دوبعدی است. در چارچوب پیشنهادی، تصویر بخش آسیب دیده خودرو به عنوان ورودی در اختیار مدل قرار گرفته و پس از پردازش، نوع آسیب شناسایی می شود. چنین رویکردی می تواند به عنوان ابزاری پشتیبان در مراحل اولیه ارزیابی خسارت مورد استفاده قرار گیرد و با کاهش بخشی از فرآیندهای دستی، مدت زمان مورد نیاز برای تشخیص اولیه آسیب و رسیدگی به پرونده های خسارت را کاهش دهد.

ساختار ادامه مقاله به این صورت است که ابتدا مبانی نظری و پیشینه پژوهش در زمینه یادگیری عمیق، شبکه های عصبی پیچشی و کاربرد آن ها در پردازش تصویر و تشخیص آسیب بررسی می شود. سپس در بخش روش شناسی، نحوه گردآوری و آماده سازی داده ها، دسته بندی تصاویر، معماری شبکه های مورد استفاده و فرآیند آموزش و ارزیابی مدل ها تشریح می شود. در ادامه، نتایج حاصل از اجرای مدل ها ارائه و عملکرد آن ها بر اساس شاخص های ارزیابی مقایسه و تحلیل می شود. در نهایت، یافته های پژوهش جمع بندی شده و محدودیت ها، پیشنهادهایی برای پژوهش های آتی و زمینه های کاربرد عملی مدل در صنعت بیمه ارائه خواهد شد.

۱. مروریات

در سال های اخیر تمرکز سازمان ها بر توسعه سامانه های خودکار به منظور برداشت و ارزیابی بهتر اطلاعات بوده و تحقیقات گسترده ای در این زمینه انجام شده است (Han et al., 2022). حضور در بازار پر تلاطم رقابت، سازمان ها را به استفاده از رویکرد نوین جهت نگهداشت مشتریان جاری، شناسایی و جذب مشتریان جدید سوق داده است. در آینده نزدیک، صنعت بیمه یکی از سریع ترین صنایع در حال رشد با استفاده از تشخیص تصویر خواهد بود. هر روزه با افزایش تعداد افرادی که رانندگی می کنند، تعداد تصادفات و ادعاهای بیمه اتومبیل افزایش یافته است. چرخه عمر ثبت، پردازش و تصمیم گیری برای هر ادعا شامل بررسی دستی فرد خدمات دهنده است که گزارش خسارت را آماده کرده و فرد ارزیاب؛ بازرسی فیزیکی از شرکت بیمه انجام میدهد که فرایندی زمانبر است. شبکه های عصبی پیچشی یا هم گشتی (CNN) از جمله مشهورترین شبکه های مبتنی بر یادگیری عمیق هستند که کاربرد گسترده ای در استخراج خودکار قوانین و مشخصه ها از انواع داده ها نظیر متن، تصویر و فیلم دارد (Snoek et al., 2012). صنعت بیمه در ایران، یک صنعت بسیار قدیمی با داشتن قوانین ثابت، محکم و چارچوب مدار است. به همین دلیل، بسیاری از فعالان و علاقه مندان فناوری های تکنولوژیکی در صنعت بیمه نسبت به سایر حوزه ها، کمتر ورود داشته اند. میدانییم صنعت بیمه با تمام پیشرفتی که از زمان تاسیس تا اکنون داشته است اما هنوز درگیر فرایندهای دستی و

کاغذی است. مشتریان بیشتر از آنچه انتظار می‌رود برای دریافت خدمات بیمه درگیر فرایند اداری کار میشوند و برای دریافت خدمات معمول، هزینه‌های مازاد پرداخت می‌کنند. با ایجاد بستر شخصی سازی، شرکت‌های بیمه می‌توانند در خدمات متناسب با نیازهای منحصر به فرد کاربران؛ موفق‌تر عمل کنند و در زمان خود صرفه جویی کنند. با توجه به گستره‌ی کاربرد هوش مصنوعی و مشتقات آن، مقالات بسیاری طی دهه گذشته، منتشر گردیده است برخی از مقالات با توجه به موضوعی که این پژوهش دنبال میکند جهت نزدیکی نسبت به سایر مقالاتی است که در این شاخه فعالیت میکنند. جدول ۱ به طور خلاصه مطالعات پیشین حوزه مورد بررسی این تحقیق را در ابعاد مختلف نشان می‌دهد.

جدول (۱) دسته بندی مقالات مرتبط با این تحقیق

منابع	مطالعه موردی	روش و الگوریتم	ویژگی‌ها													
			Supervised	Unsupervised	Multivariate	Univariate	Global	Local	Dynamic	Static	Splitting	Merging	Direct	Incremental	Parametric	Non-Parametric
(Najafabadi et al., 2015)	آموزشی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Nielsen, 2015)	تحقیقاتی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Young et al., 2015)	آموزشی-کاربردی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Bhandare et al., 2016)	آموزشی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Goodfellow et al., 2016)	روسازی جاده ای	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Nejad et al., 2016)	تحقیقاتی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Albelwi & Mahmood, 2017)	جاده ای	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Gopalakrishnan et al., 2017)	خودروسازی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Harshani & Vidanage, 2017)	تحقیقاتی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Li et al., 2017)	خودروسازی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Wiatowski & Bölcskei, 2017)	نظری-ریاضی	Technique	✓	✓	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
(Zhang and Cheng, 2017)	ساخت و روسازی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Dorafshan et al., 2018)	ساخت و ساز-بتن	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Eom & Choi, 2018)	تحقیقاتی- ترکیبی	CNN	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Gao & Mosalam, 2018)	عمران-ساختاری	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Gopalakrishnan, 2018)	ساخت و روسازی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×

تشخیص آسیب خودرو پس از تصادفات با استفاده از شبکه های عصبی عمیق

(Gopalakrishnan et al., 2018)	حمل و نقل هوایی-غیر نظامی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	×	✓	×	×	✓	×
(Kim et al., 2018)	ساخت و ساز	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Li et al., 2018)	بیمه خودرو-کلاهبرداری	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Tong et al., 2018)	عمرانی-جاده ای	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Zhang, Cheng et al., 2018)	عمرانی-جاده ای	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Amin, Hijji et al., 2019)	حوادث طبیعی-سیل	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Kumar, Srivastava et al., 2019)	بیمه-تحقیقاتی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Qi, Chen et al., 2019)	آموزشی-کاربردی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Riantini et al., 2019)	امدادسانی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Singh, Ayyar et al., 2019)	مطالبات بیمه	Information	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Li, Wang et al., 2020)	عمران	Image ,CNN processing	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	✓	×	×	×
(Prykaziuk, Erastov et al., 2020)	بیمه-مروری	Information	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	✓	×	×	×
(Ranjbar, Moghaddasnezhad et al., 2020)	عمران	Information	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	✓	×	×	×
(سجاد، فریدون و همکاران، ۲۰۲۰)	عمران	Information	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	✓	×	×	×
(بیگدلی و جباری، ۲۰۲۱)	عمران-سازه	CAD- Image processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Han, Pei et al., 2022)	آموزشی	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(Maiano, Montuschi et al., 2023)	خودرو	Image ,CNN processing	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	✓	×	×	×
(Qaddour and Siddiqa, 2023)	خودرو	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
این تحقیق	آسیب خودرو-بیمه	Image ,CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×

۲. شکاف تحقیق و تعریف مسئله

بررسی مطالعات ارائه شده در جدول ۱ مرور ادبیات نشان می دهد که اگرچه در سال های اخیر استفاده از یادگیری عمیق و الگوریتم های بینایی ماشین در حوزه های مختلف صنعت خودرو توسعه یافته است، به کارگیری این روش ها با تمرکز مشخص بر شناسایی و طبقه بندی انواع خسارت خودرو پس از تصادف همچنان به صورت محدود مورد توجه قرار گرفته است. بخش قابل توجهی از مطالعات پیشین بر موضوعاتی نظیر تشخیص اشیاء، شناسایی عیوب، پایش وضعیت و کاربردهای عمومی پردازش تصویر تمرکز داشته اند و بررسی جامع خسارت های خودرو در قالب چند کلاس مختلف کمتر مورد مطالعه قرار گرفته است. یکی دیگر از شکاف های قابل مشاهده در مطالعات پیشین، محدود بودن دامنه انواع خسارت ها و همچنین تعداد مدل های مورد مقایسه است. در پژوهش حاضر، شش گروه از آسیب های خودرو شامل آسیب سطحی، آسیب عمیق، آسیب آینه جانبی، آسیب شیشه، آسیب لاستیک و آسیب چراغ خودرو مورد بررسی قرار گرفته است. همچنین برای ارزیابی

و مقایسه عملکرد مدل‌ها، هفت معماری یادگیری عمیق شامل AlexNet، VGG-۱۹، ResNet-۵۰، ResNet-۱۰۱، EfficientNetB، و L2EfficientNetV و MobileNetV۲ به کار گرفته شده‌اند. استفاده هم‌زمان از چندین معماری امکان مقایسه جامع‌تر عملکرد مدل‌ها و انتخاب روش مناسب‌تر برای مسئله تشخیص خسارت خودرو را فراهم می‌کند.

از سوی دیگر، در بسیاری از مطالعات پیشین از مجموعه داده‌های عمومی، محدود یا غیرواقعی استفاده شده و ارزیابی مدل‌ها نیز در برخی موارد تنها بر اساس یک یا چند معیار محدود انجام گرفته است. در پژوهش حاضر تلاش شده است با استفاده از داده‌های واقعی مربوط به تصادفات و خسارت‌های خودرو در سال‌های اخیر، شرایط مسئله تا حد امکان به محیط واقعی صنعت بیمه و ارزیابی خسارت نزدیک شود. علاوه بر این، عملکرد مدل‌ها با استفاده از شاخص‌های مختلف ارزیابی، از جمله دقت، حساسیت و سایر معیارهای مرتبط، مورد بررسی قرار گرفته است تا قابلیت اعتماد به نتایج افزایش یابد.

بر این اساس، نوآوری اصلی پژوهش حاضر را می‌توان در به کارگیری و مقایسه چندین معماری نوین یادگیری عمیق برای تشخیص چندکلاسه خسارت خودرو بر مبنای داده‌های واقعی دانست. توسعه چنین رویکردی می‌تواند زمینه لازم برای خودکارسازی بخشی از فرآیند ارزیابی خسارت در شرکت‌های بیمه، شرکت‌های خودروسازی و سایر سازمان‌های مرتبط را فراهم کند. کاهش زمان تشخیص و ارزیابی اولیه خسارت، تسریع فرآیند رسیدگی به پرونده‌ها، افزایش یکپارچگی ارزیابی‌ها و فراهم شدن امکان تصمیم‌گیری سریع‌تر از جمله ظرفیت‌های کاربردی چنین سامانه‌ای است. بنابراین، این پژوهش علاوه بر توسعه کاربردهای هوش مصنوعی و بینایی ماشین در حوزه خودرو، می‌تواند گامی در جهت ایجاد زیرساخت‌های لازم برای استفاده عملیاتی از این فناوری‌ها در صنعت بیمه و خودروسازی کشور باشد.

۳. روش شناسی

هوش مصنوعی حوزه‌ای گسترده از علوم رایانه است که به طراحی و توسعه سیستم‌هایی با قابلیت یادگیری، استدلال، تشخیص الگو و تصمیم‌گیری می‌پردازد. یادگیری ماشین به عنوان یکی از زیرشاخه‌های هوش مصنوعی، به سیستم‌ها امکان می‌دهد با استفاده از داده‌های آموزشی، الگوها و روابط موجود را شناسایی و برآزش کرده و بر اساس آن‌ها درباره داده‌های جدید پیش‌بینی یا تصمیم‌گیری کنند. یادگیری عمیق نیز به عنوان شاخه‌ای پیشرفته از یادگیری ماشین، در سال‌های اخیر نقش مهمی در توسعه کاربردهای پردازش تصویر و بینایی ماشین داشته است. در این میان، شبکه‌های عصبی پیچشی (CNN) به دلیل توانایی در استخراج خودکار ویژگی‌های تصویری، از جمله لبه‌ها، بافت‌ها و اشکال، کاربرد گسترده‌ای در تشخیص و طبقه‌بندی تصاویر یافته‌اند. عملکرد این شبکه‌ها به عواملی همچون حجم و کیفیت داده‌های آموزشی، معماری مدل و نحوه آموزش وابسته است و استفاده از داده‌های مناسب و متنوع می‌تواند قابلیت تعمیم و دقت مدل را در مواجهه با تصاویر جدید بهبود دهد. یادگیری ماشین به سه شکل اصلی زیر تقسیم می‌شود:

۱. یادگیری نظارت شده در این روش، مدل با استفاده از داده‌های ورودی و خروجی متناظرشان آموزش داده می‌شود. هدف اصلی

در یادگیری نظارت شده، پیش‌بینی خروجی‌ها برای داده‌های جدید است.

^۱ Supervised Learning

۲. یادگیری بدون نظارت^۱ در این روش، مدل بدون داشتن خروجی های متناظر با داده ها، آموزش می بیند. هدف اصلی در یادگیری بدون نظارت، استخراج الگوها، ساختارها و روابط مخفی در داده ها است.

۳. یادگیری تقویتی^۲ نیز یک شاخه دیگر از یادگیری ماشین است که بر اساس سیستم های مبتنی بر پاداش و جریمه عمل می کند. در این روش، عامل (Agent) با تعامل با یک محیط و دریافت پاداش ها و جریمه ها، تلاش می کند رفتاری را یاد بگیرد که بیشترین پاداش را به دست آورد.

در یادگیری بدون نظارت، داده های ورودی بدون برچسب یا خروجی مشخص در اختیار مدل قرار می گیرند. هدف اصلی در این روش، استخراج الگوها، ساختارها و روابط مخفی در داده ها است. در این حالت، مدل به صورت خودکار بدون هدایت برچسب ها یا خروجی های صحیح، الگوها و ارتباطات معنایی در داده ها را کشف می کند. یادگیری عمیق^۳ یک شاخه از یادگیری ماشین است که بر پایه ساختار شبکه های عصبی مصنوعی^۴ استوار است. این روش، مدل سازی قدرتمندی را برای تشخیص الگوها و استخراج ویژگی های پیچیده از داده ها فراهم می کند. شبکه های عصبی عمیق مبتنی بر مدل های سلسله مراتبی هستند که هر لایه با یک انتقال خطی پس از اعمال تبدیل غیر خطی به لایه بعد مرتبط میشود. در یک مثال ساده میتوان داده های ورودی را به صورت $X \in R^{N \times D}$ فرض نمود که هر ردیف از X یک داده با بعد D مثل تصاویر خاکستری با D پیکسل است و N تعداد نمونه ها آموزشی شبکه است. در این شبکه W^k به صورت ماتریسی برای انتقال خطی از لایه $k-1$ به مرحله دیگر جهت کاهش ابعاد در لایه k تعریف میشود.

$$X_{k-1} W^k \in R^{N \times d_k} \quad (۱)$$

در مرحله بعد، یک تابع غیر خطی ψ_k برای ایجاد لایه k ام مورد استفاده قرار میگیرد.

$$X_k = \psi_k(X_{k-1} W^k) \quad (۲)$$

این تابع غیر خطی میتوان به اشکال مختلفی نظیر تابع $\tanh(x)$ یا

$(1 + e^{-x})^{-1}$ غیره تعریف و به کار گرفته شود. با توجه به روند شرح داده شده، خروجی شبکه پس از چندین لایه به صورت زیر مشخص میشود:

$$\phi(X, W^1, W^2, \dots, W^k) = \psi_k(\psi_{k-1}(\dots(\psi_2(\psi_1(XW^1)W^2) \dots)W^{k-1})W^k) \quad (۳)$$

که در رابطه فوق، ϕ یک ماتریس $N \times C$ بوده و C بعد خروجی شبکه است که در یک شبکه با هدف دسته بندی تعداد دسته ها به عنوان بعد خروجی در نظر گرفته میشود. یادگیری پارامترهای شبکه عمیق با توجه به N داده ی آموزشی به صورت یک مسئله بهینه سازی مطرح میشود. بدین صورت که در یک مسئله با هدف دسته بندی، هر ردیف از X یک داده را در R^D مشخص میکند و هر Y یکی از اعضای کلاسهای خروجی C را مشخص میکند. بر این اساس فرایند یادگیری به صورت زیر صورت میگیرد.

$\text{Min}l(Y, \phi(X, W^1, W^2, \dots, W^k)) + \lambda \theta(W^1, W^2, \dots, W^k)$	$X \in R^{N \times D} Y \in R^{N \times C}$	(۴)
--	---	-------


^۱ Unsupervised Learning

^۲ Reinforcement Learning

^۳ Deep Learning


^۴ Artificial Neural Networks

در رابطه فوق، یک تابع زیان $\ell(Y, \hat{Y})$ از پیش تعیین شده تفاوت بین کلاسهای پیش تعیین شده و کلاس های پیش بینی شده بر اساس رابطه (Θ) برای جلوگیری از اضافه برآزش مدل و λ به عنوان پارامتر تعدیل با مقدار مثبت در نظر گرفته میشود. در شکل ۱ نمایی کلی از ساختار عصبی پیچشی در این پژوهش ارائه شده است.



شکل (۱) ساختار عصبی کانولوشنال (پیچشی) در این پژوهش^۱

شبکه عصبی کانولوشن یکی از مهم ترین شبکه های عصبی عمیق است که معماری آن از الگویی مشابه اتصال نرون های مغز به یکدیگر پیروی می کند و از بخش Visual Cortex (بخش متعلق به بینایی مغز) الگو برداری شده است. دسته های کوچکی از نرون های بینایی در هر قسمت به تنهایی مشغول است و از ترکیب این نرون ها و ایجاد شبکه های به هم پیوسته باعث دیدن یک منطقه می شود.




شکل (۲) نحوه ایجاد لایه ترکیب به روش الف: انتخاب بیشینه (max pooling) ب: میانگین (average pooling)

مطابق شکل ۲ لایه کانولوشن، ستون فقرات هر مدل کاری CNN است. این لایه همان لایه ای است که اسکن پیکسل به پیکسل از تصاویر در آن صورت می گیرد و یک نقشه ویژگی برای تعریف طبقه بندی های آینده ایجاد می کند. مطابق شکل ۳ لایه پولینگ با آوردن ابعاد کلی تصاویر به عنوان نمونه برداری از داده ها نیز شناخته می شود. اطلاعات هر ویژگی از هر لایه کانولوشن محدود به اطلاعات ضروری است. روند ایجاد لایه های کانولوشن و استفاده از pooling مداوم است، ممکن است چندین بار استفاده شود.

^۱ A Typical Convolutional Neural Network (CNN)

layer Convolutional^۲

Pooling layer^۳



شکل (۳) کانوال داده ها

لایه مسطح سازی (Flatten Layer) وظیفه دارد خروجی چندبعدي حاصل از لایه های پیشین را به یک بردار یک بعدی تبدیل کند تا داده ها برای ورود به لایه های بعدی شبکه آماده شوند. به بیان دیگر، ویژگی های استخراج شده از تصویر در این مرحله بدون تغییر در مقادیر، به یک ساختار برداری تبدیل می شوند. پس از آن، لایه تمام متصل (Fully Connected Layer) قرار می گیرد. در این لایه، تمامی نورون های لایه قبلی به نورون های لایه بعد متصل هستند و شبکه با استفاده از وزن های آموخته شده در فرآیند آموزش، ویژگی های استخراج شده را برای انجام طبقه بندی ترکیب و تحلیل می کند. برخلاف مقداردهی اولیه وزن ها که ممکن است به صورت تصادفی انجام شود، مقادیر وزن ها در طول فرآیند آموزش و با استفاده از الگوریتم های بهینه سازی به روزرسانی می شوند. در نهایت، لایه خروجی (Output Layer) آخرین بخش شبکه عصبی پیچشی است که نتایج نهایی طبقه بندی را تولید می کند. تعداد نورون های این لایه معمولاً متناسب با تعداد کلاس های مسئله تعیین می شود و خروجی آن می تواند احتمال تعلق تصویر ورودی به هر یک از کلاس ها را مشخص کند. سپس بر اساس این مقادیر، کلاس نهایی تصویر تعیین می شود.

در شکل ۴، فرآیند کلی اعمال عملیات کانولوشن بر داده های تصویری و نحوه استخراج ویژگی ها نمایش داده شده است. شبکه عصبی پیچشی (CNN) تصویر را به عنوان ورودی دریافت کرده و از طریق مجموعه ای از لایه های کانولوشن، فعال سازی و تجمیع، ویژگی های مهم تصویر را استخراج می کند. یکی از مزایای مهم این شبکه ها، کاهش نیاز به استخراج دستی ویژگی ها و انجام پیش پردازش های پیچیده در مقایسه با بسیاری از روش های سنتی یادگیری ماشین است. البته بسته به نوع داده، انجام برخی عملیات پیش پردازش مانند تغییر اندازه تصاویر، نرمال سازی مقادیر پیکسل ها و حذف داده های نامناسب همچنان می تواند ضروری باشد. معماری شبکه های عصبی پیچشی به گونه ای طراحی شده است که ضمن استخراج ویژگی های مکانی تصاویر، با استفاده از لایه هایی نظیر Pooling یا عملیات دارای گام حرکتی، ابعاد داده ها را در بخش هایی از شبکه کاهش دهد. این ویژگی موجب کاهش حجم محاسبات و کمک به یادگیری مؤثرتر الگوهای موجود در تصاویر می شود و شبکه را قادر می سازد ساختارها و ویژگی های پیچیده تر تصویری را در لایه های عمیق تر شناسایی کند.

این پژوهش از نظر هدف، توسعه ای - کاربردی و از نظر روش، مبتنی بر رویکردهای یادگیری ماشین و الگوریتم های یادگیری عمیق است. در این پژوهش، با استفاده از تصاویر واقعی مربوط به خودروهای آسیب دیده طی دو سال، مدل هایی برای تشخیص و طبقه بندی نوع آسیب خودرو توسعه و ارزیابی شده اند. پس از جمع آوری و آماده سازی داده ها، تصاویر به دو مجموعه آموزش و آزمون، به ترتیب با نسبت ۷۰ و ۳۰ درصد، تقسیم شدند. همچنین تصاویر بر اساس نوع آسیب در شش گروه شامل آسیب سطحی خودرو مانند خراش، آسیب عمیق مانند شکستگی و فرو رفتگی، آسیب آینه جانبی، شیشه، لاستیک و چراغ خودرو طبقه بندی شدند.

در این پژوهش، به منظور توسعه مدل های تشخیص آسیب از رویکرد انتقال یادگیری (Transfer Learning) و شبکه های عصبی از پیش آموزش دیده استفاده شده است. در انتقال یادگیری، دانش و ویژگی هایی که شبکه طی آموزش اولیه بر روی مجموعه داده های بزرگ فراگرفته است، برای حل مسئله جدید مورد استفاده قرار می گیرد. بر این اساس، شبکه های از پیش آموزش دیده متناسب با تصاویر خسارت

خودرو بازآموزی و تنظیم شده‌اند. این رویکرد، در مقایسه با آموزش یک شبکه عمیق از ابتدا، امکان توسعه مدل با تعداد داده‌های کمتر، زمان آموزش کوتاه‌تر و نیاز محاسباتی پایین‌تر را فراهم می‌کند. مشخصات شبکه‌های از پیش آموزش دیده مورد استفاده در پژوهش در جدول ۲ ارائه شده است.

جدول (۲) مشخصات و اطلاعات مدل های از پیش تعلیم یافته

تعداد داده مورد استفاده در ساخت شبکه	سایز (مگابایت)	تعداد پارامترها (میلیون)	تعداد لایه ها (عمق شبکه)	ابعاد تصاویر (پیکسل)	مدل آموزش دیده
	227	61	8	227*227*3	AlexNet
	549	143.7	84	224*224*3	VGG-19
بیش از یک میلیون تصویر در ۱۰۰۰ دسته	98	25.6	58	224*224*3	ResNet-50
	171	44.7	90	224*224*3	ResNet-101
	256	66.7	438	224*224*3	EfficientNetB7
	479	119.0	..	224*224*3	EfficientNetV2L
	14	4.3	55	224*224*3	MobNetV2

در مرحله آماده‌سازی داده‌ها، تصاویر گردآوری شده پس از انجام عملیات اولیه شامل بررسی کیفیت داده‌ها، حذف تصاویر نامناسب، تغییر اندازه تصاویر متناسب با ورودی شبکه و نرمال‌سازی، برای ورود به مدل آماده شدند. مجموعه داده این پژوهش شامل ۴۱۰۰ تصویر واقعی از آسیب‌های وارد شده به خودرو با ابعاد اولیه متوسط حدود ۳۲۴۰×۴۳۲۰ پیکسل است. این تصاویر بر اساس نوع آسیب در شش گروه مذکور طبقه‌بندی شدند و سپس برای آموزش و آزمون شبکه‌های مختلف مورد استفاده قرار گرفتند. تنوع و تعداد مناسب تصاویر در هر گروه از اهمیت ویژه‌ای برخوردار است؛ زیرا محدود بودن نمونه‌های آموزشی می‌تواند احتمال بیش‌برازش (Overfitting) را افزایش دهد. از سوی دیگر، افزایش تعداد و تنوع نمونه‌های آموزشی، ضمن فراهم کردن امکان یادگیری الگوهای متنوع‌تر، موجب افزایش زمان آموزش و توان پردازشی موردنیاز نیز می‌شود. از این رو، آماده‌سازی مناسب داده‌ها و ایجاد تنوع کافی در نمونه‌های آموزشی از مراحل مهم توسعه مدل‌های تشخیص آسیب در این پژوهش محسوب می‌شود. در نهایت، عملکرد شبکه‌های مختلف با استفاده از معیارهای متداول ارزیابی مدل‌های طبقه‌بندی مورد بررسی و مقایسه قرار گرفت تا مناسب‌ترین معماری برای تشخیص انواع آسیب خودرو مشخص شود. در ابتدا، داده‌های آموزشی برای مدل جمع‌آوری و آماده‌سازی پایگاه داده (تمیزکاری داده‌ها، نرمال‌سازی و...) آماده می‌شوند و به دو دسته آموزش و تست و ۶ زیرگروه آسیب سطحی خودرو همانند خراش، آسیب عمیق خودرو همانند شکستگی، آینه جانبی خودرو، شیشه، لاستیک و چراغ ماشین کلاس بندی (Clustering) میشوند. هرچه تنوع و تعداد تصاویر در هر دسته بیشتر باشد، احتمال بروز مشکل اضافه‌برازش (Overfitting) کاهش می‌یابد؛ همچنین زمان تعلیم مدل ها و توان پردازشی افزایش می‌یابد. در این پژوهش از ۴۱۰۰ تصویر از آسیب خودرو با ابعاد متوسط ۳۲۴۰×۴۳۲۰ پیکسل استفاده شده است. نمونه‌هایی از تصاویر مورد استفاده در مجموعه داده پژوهش در شکل ۵ ارائه شده‌اند.




شکل (۵) نمونه داده های استفاده شده

جدول (۳) داده های استفاده شده در این پژوهش

تعداد داده های استفاده شده در این پژوهش		دسته بندی
تست	آموزش	
219	1291	آسیب سطحی خودرو
496	798	آسیب عمیق خودرو
29	53	آسیب شیشه خودرو
23	54	آسیب آینه جانبی خودرو
206	881	آسیب چراغ خودرو
6	8	آسیب لاستیک خودرو
4062		مجموع

در مرحله آموزش، داده های ورودی در اختیار مدل قرار گرفته و پس از محاسبه خروجی پیش بینی شده و مقایسه آن با مقدار واقعی، میزان خطا تعیین می شود. سپس با استفاده از الگوریتم پس انتشار خطا (Backpropagation)، وزن های شبکه به روزرسانی می شوند. این فرآیند طی چندین دوره آموزشی (Epoch) تکرار می شود تا میزان خطا کاهش یافته و عملکرد مدل به وضعیت پایداری برسد. پس از آماده سازی و پیش پردازش تصاویر، در مجموع ۴۰۶۲ تصویر در فرآیند یادگیری مدل ها مورد استفاده قرار گرفت که از این تعداد، ۳۰۸۵ تصویر به مجموعه آموزش و ۹۷۷ تصویر به مجموعه اعتبارسنجی اختصاص یافت. پیاده سازی و آموزش مدل ها با استفاده از زبان برنامه نویسی Python و کتابخانه های TensorFlow، NumPy، Matplotlib و Glob انجام شد. پس از پایان آموزش، عملکرد مدل ها با استفاده از داده های اعتبارسنجی و بر اساس معیارهایی نظیر دقت (Accuracy)، صحت یا دقت مثبت (Precision)، حساسیت یا فراخوانی (Recall/Sensitivity) و سایر شاخص های مرتبط مورد ارزیابی و مقایسه قرار گرفت. در صورت مشاهده عملکرد نامطلوب، تنظیم پارامترهای آموزشی و ابرپارامترهای مدل به منظور دستیابی به عملکرد مناسب تر انجام شد.



شکل (۶) نمونه ای از روند آموزش داده ها

همان گونه که در شکل ۶ مشاهده می شود، تغییرات خطا و دقت مدل ها پس از حدود ۱۰ تا ۱۲ دوره آموزشی به وضعیت نسبتاً پایداری رسیده است؛ از این رو، تعداد ۱۵ دوره آموزشی (Epoch) برای آموزش مدل ها در نظر گرفته شد. اندازه دسته (Batch Size) نیز برای اغلب مدل ها برابر با ۱۵ تعیین شد. تعداد تکرارهای هر دوره بر اساس رابطه (۵) محاسبه می شود.

$$i = \frac{N}{n} \quad (۵)$$

که در آن (N) تعداد داده های آموزشی و (n) اندازه دسته است. با توجه به ۳۰۸۵ تصویر آموزشی و اندازه دسته ۱۵، در هر دوره حدود ۲۰۶ تکرار انجام می شود. نرخ یادگیری و مقدار تکانه نیز به ترتیب برابر با ۰,۰۰۱ و ۰,۰۹ در نظر گرفته شدند. به منظور ایجاد شرایط یکسان برای مقایسه مدل ها، تنظیمات آموزشی تا حد امکان مشابه بود؛ با این حال، به دلیل محدودیت حافظه، اندازه دسته برای مدل ResNet-101 برابر با ۱۲ تعیین شد. پیاده سازی و اجرای مدل ها با استفاده از Python و Google Colab و بر روی سیستمی مجهز به پردازنده گرافیکی NVIDIA GeForce RTX 3060 با ۱۲ گیگابایت حافظه انجام شد. مهم ترین محدودیت های پژوهش شامل نیاز به توان پردازشی مناسب، وابستگی عملکرد مدل به حجم و کیفیت داده های آموزشی، وجود نویز در تصاویر و تأثیر متغیرهایی مانند زاویه تصویربرداری، روشنایی و شدت آسیب بر دقت مدل است. همچنین، به دلیل ماهیت احتمالاتی مدل های یادگیری عمیق، نمی توان انتظار عملکرد کاملاً بدون خطا در تمامی شرایط را داشت.

۴. یافته های پژوهش

پس از انجام فرآیند آموزش مدل ها و ارزیابی آن ها بر اساس داده های آزمون، عملکرد مدل ها از نظر سرعت آموزش، زمان پیش پردازش و زمان ارزیابی مورد بررسی قرار گرفت. نتایج مربوط به زمان اجرای مدل ها در جدول ۴ ارائه شده است.


جدول (۴) زمان آموزش، پیش پردازش و ارزیابی مدل ها

مدل	زمان آموزش مدل ها (ثانیه)	زمان پیش پردازش برای هر تصویر (ثانیه)	زمان ارزیابی مدل ها (ثانیه)
AlexNet	0/482	0	0/019
VGG-19	0/637	0	0/024
ResNet-50	1/944	0/056	0/041
ResNet-101	3/823	0	0/054
EfficientNetB7	61/85	0	0/061

تشخیص آسیب خودرو پس از تصادفات با استفاده از شبکه های عصبی عمیق

EfficientNetV2L	64/25	0	0.056
MobiNetV2	0.55	0	0/034

با توجه به جدول ۴، تفاوت قابل توجهی میان مدل ها از نظر زمان آموزش و ارزیابی مشاهده می شود. به منظور مقایسه بهتر سرعت عملکرد مدل ها، نتایج مربوط به فرآیند آموزش و ارزیابی به ترتیب در شکل های ۷ و ۸ نمایش داده شده است.



شکل (۷) مقایسه سرعت مدل ها در فرآیند آموزش

مدل های AlexNet، VGG-19، MobileNetV2 و ResNet-50 زمان آموزش کمتری نسبت به مدل های پیچیده تر داشته اند (شکل ۷).



شکل (۸) مقایسه سرعت مدل ها در فرآیند ارزیابی

با توجه به شکل ۸، زمان ارزیابی تمامی مدل ها نسبت به زمان آموزش کمتر بوده است. در میان مدل های مورد بررسی، AlexNet با زمان آموزش ۰,۴۸۲ ثانیه و زمان ارزیابی ۰,۰۱۹ ثانیه به ازای هر تصویر، سریع ترین عملکرد را داشته است. در مقابل، EfficientNetV2L با زمان آموزش ۶۴,۲۵ ثانیه، بیشترین زمان آموزش را به خود اختصاص داده است. با توجه به نتایج جدول ۴ و شکل های ۷ و ۸، مدل های AlexNet، VGG-19، MobileNetV2 و ResNet-50 از نظر زمان آموزش و ارزیابی عملکرد سریع تری نسبت به سایر مدل ها داشتند. در میان مدل های مورد بررسی، AlexNet با زمان آموزش ۰,۴۸۲ ثانیه و زمان ارزیابی ۰,۰۱۹ ثانیه به ازای هر تصویر، سریع ترین عملکرد را نشان داد؛ در مقابل، EfficientNetV2L بیشترین زمان آموزش را به خود اختصاص داد. جدول ۵ عملکرد کلی مدل ها را بر اساس شاخص های Accuracy، Sensitivity، Specificity، Precision و F-score در کلاس های مختلف آسیب نشان می دهد.


جدول (۵) ارزیابی کلی عملکرد مدل ها

F- score	Precision	Specificity	Sensitivity	Accuracy	class	model
۰/۳۱۵	۰/۳۱۳	۰/۳۱۰	۰/۳۱۵	۰/۳۱۲	آسیب عمیق	AlexNet
۰/۳۵۶	۰/۳۵۶	۰/۳۱۴	۰/۳۵۶	۰/۳۲۸	آسیب آینه جانبی خودرو	
۰/۳۲۸	۰/۳۷۱	۰/۳۱۴	۰/۳۶۹	۰/۳۳۵	آسیب شیشه	
۰/۳۱۲	۰/۳۴۷	۰/۳۱۲	۰/۳۴۷	۰/۳۴۱	آسیب لاستیک	
۰/۳۳۶	۰/۳۲۰	۰/۳۳۵	۰/۳۳۶	۰/۳۱۴	آسیب سطحی	
۰/۳۲۸	۰/۳۲۸	۰/۳۲۰	۰/۳۲۸	۰/۳۱۲	چراغ خودرو	
۰/۳۲۹	۰/۳۳۹	۰/۳۱۸	۰/۳۴۲	۰/۳۲۴	کل	VGG-19
۰/۴۱۵	۰/۴۱۵	۰/۴۱۲	۰/۴۱۵	۰/۴۲۲	آسیب عمیق	
۰/۴۵۶	۰/۴۵۶	۰/۴۱۴	۰/۴۵۶	۰/۴۵۸	آسیب آینه جانبی خودرو	
۰/۴۲۸	۰/۴۷۱	۰/۴۱۴	۰/۴۶۹	۰/۴۳۵	آسیب شیشه	
۰/۴۱۲	۰/۴۴۷	۰/۴۱۲	۰/۴۴۷	۰/۴۴۱	آسیب لاستیک	
۰/۴۳۶	۰/۴۲۰	۰/۴۳۵	۰/۴۳۶	۰/۴۱۴	آسیب سطحی	
۰/۴۲۸	۰/۴۲۸	۰/۴۲۰	۰/۴۲۸	۰/۴۱۲	چراغ خودرو	ResNet-50
۰/۴۲۹	۰/۴۴۰	۰/۴۱۸	۰/۴۴۲	۰/۴۳۰	کل	
۰/۵۱۵	۰/۵۱۵	۰/۵۴۲	۰/۵۱۵	۰/۵۱۲	آسیب عمیق	
۰/۵۵۶	۰/۵۵۶	۰/۵۴۴	۰/۵۵۶	۰/۵۲۸	آسیب آینه جانبی خودرو	
۰/۵۲۸	۰/۵۷۱	۰/۵۱۴	۰/۵۲۹	۰/۵۳۵	آسیب شیشه	
۰/۵۱۲	۰/۵۴۷	۰/۵۵۲	۰/۵۴۷	۰/۵۲۱	آسیب لاستیک	
۰/۵۳۶	۰/۵۲۰	۰/۵۳۵	۰/۵۳۶	۰/۵۱۴	آسیب سطحی	ResNet-101
۰/۵۲۸	۰/۵۲۸	۰/۵۳۰	۰/۵۲۸	۰/۵۱۲	چراغ خودرو	
۰/۵۲۹	۰/۵۴۰	۰/۵۳۶	۰/۵۳۷	۰/۵۲۰	کل	
۰/۵۱۵	۰/۵۱۵	۰/۵۱۲	۰/۵۱۵	۰/۵۱۲	آسیب عمیق	
۰/۵۵۶	۰/۶۸۶	۰/۵۱۴	۰/۵۵۶	۰/۵۲۸	آسیب آینه جانبی خودرو	
۰/۵۲۸	۰/۶۷۱	۰/۵۱۴	۰/۵۶۹	۰/۵۳۵	آسیب شیشه	
۰/۵۱۲	۰/۵۴۷	۰/۵۱۲	۰/۵۴۷	۰/۵۴۱	آسیب لاستیک	EfficientNetB7
۰/۵۳۶	۰/۵۲۰	۰/۵۳۵	۰/۵۳۶	۰/۵۱۴	آسیب سطحی	
۰/۵۲۸	۰/۵۲۸	۰/۵۲۰	۰/۵۲۸	۰/۵۱۲	چراغ خودرو	
۰/۵۲۹	۰/۵۷۸	۰/۵۱۸	۰/۵۴۲	۰/۵۲۴	کل	
۰/۵۸۵	۰/۵۷۵	۰/۵۹۵	۰/۵۱۵	۰/۵۷۴	آسیب عمیق	
۰/۵۵۶	۰/۵۵۶	۰/۵۳۴	۰/۶۰۰	۰/۶۸۵	آسیب آینه جانبی خودرو	
۰/۵۸۴	۰/۵۷۹	۰/۵۷۴	۰/۵۶۹	۰/۵۷۵	آسیب شیشه	EfficientNetV2L
۰/۵۶۵	۰/۵۴۷	۰/۵۹۲	۰/۵۹۷	۰/۶۲۱	آسیب لاستیک	
۰/۵۹۶	۰/۵۶۶	۰/۵۸۵	۰/۵۹۶	۰/۵۲۴	آسیب سطحی	
۰/۵۵۸	۰/۵۹۸	۰/۵۴۰	۰/۵۹۹	۰/۵۴۱	چراغ خودرو	
۰/۵۷۴	۰/۵۷۰	۰/۵۷۰	۰/۵۷۹	۰/۵۸۷	کل	
۰/۶۵۵	۰/۶۱۵	۰/۶۱۲	۰/۶۵۵	۰/۶۷۲	آسیب آینه جانبی خودرو	
۰/۶۵۶	۰/۶۵۶	۰/۶۵۴	۰/۶۹۶	۰/۶۶۶	آسیب آینه بغل	MobiNetV2
۰/۶۲۸	۰/۶۷۱	۰/۶۷۴	۰/۶۶۹	۰/۶۵۵	آسیب شیشه	
۰/۶۹۲	۰/۶۴۷	۰/۶۴۲	۰/۶۶۷	۰/۶۹۱	آسیب لاستیک	
۰/۶۷۶	۰/۶۲۰	۰/۶۳۵	۰/۶۵۶	۰/۶۸۴	آسیب سطحی	
۰/۶۲۸	۰/۶۴۸	۰/۶۶۳	۰/۶۲۸	۰/۶۹۲	چراغ خودرو	
۰/۶۵۶	۰/۶۴۳	۰/۶۴۷	۰/۶۶۲	۰/۶۷۷	کل	
۰/۵۱۵	۰/۵۰۵	۰/۵۳۲	۰/۵۱۵	۰/۵۱۲	آسیب عمیق	

تشخیص آسیب خودرو پس از تصادفات با استفاده از شبکه های عصبی عمیق


۰/۵۵۶	۰/۵۱۶	۰/۵۱۴	۰/۵۲۶	۰/۵۱۸	آسیب آینه جانبی خودرو
۰/۵۲۸	۰/۵۲۱	۰/۵۱۴	۰/۵۴۹	۰/۵۲۵	آسیب شیشه
۰/۵۱۲	۰/۵۱۷	۰/۵۱۲	۰/۵۱۷	۰/۵۴۱	آسیب لاستیک
۰/۵۳۶	۰/۵۲۰	۰/۵۳۵	۰/۵۲۶	۰/۵۱۴	آسیب سطحی
۰/۵۲۸	۰/۵۲۸	۰/۵۲۰	۰/۵۲۸	۰/۵۱۲	چراغ خودرو
۰/۵۲۹	۰/۵۱۸	۰/۵۲۱	۰/۵۲۷	۰/۵۲۰	کل

ا توجه به جدول ۵، عملکرد مدل ها در شناسایی انواع آسیب یکسان نبوده و تفاوت هایی میان معماری های مختلف مشاهده می شود. به طور کلی، مدل های عمیق تر در برخی کلاس ها عملکرد مناسب تری داشته اند، هرچند این بهبود با افزایش زمان آموزش و پیچیدگی محاسباتی همراه بوده است. در ادامه، برای بررسی دقیق تر فرآیند یادگیری، عملکرد تعدادی از مدل ها با تغییر تعداد لایه های قابل آموزش و تعداد دوره های آموزشی مورد بررسی قرار گرفت. شکل ۹ روند آموزش اولیه مدل MobileNetV2 را در شرایطی نشان می دهد که به جز لایه Dense، سایر لایه ها در حالت غیر قابل آموزش قرار گرفته اند.




شکل (۹) روند آموزش مدل MobileNetV2 در حالت اولیه

با توجه به نمودارهای موجود در شکل ۹ مقدار دقت قابل توجه نیست و در ادامه سعی خواهیم کرد آن را افزایش دهیم. برای افزایش مقدار دقت ابتدا ۱۰۰ لایه ابتدایی مدل را در حالت trainable-non قرار میدهم. شکل ۱۰ روند آموزش MobileNetV2 را پس از تغییر تعداد لایه های قابل آموزش نشان می دهد.




شکل (۱۰) روند آموزش مدل MobileNetV2 پس از تغییر تعداد لایه‌های قابل آموزش

با توجه به شکل ۱۰، افزایش تعداد لایه‌های قابل آموزش به تنهایی موجب بهبود قابل توجه دقت نشد؛ از این رو، تعداد لایه‌های قابل آموزش و تعداد دوره‌های آموزشی افزایش یافت. شکل ۱۱ روند آموزش MobileNetV2 را پس از افزایش تعداد لایه‌های قابل آموزش و تعداد دوره‌های آموزشی نشان می‌دهد.




شکل (۱۱) روند آموزش مدل MobileNetV2 پس از افزایش لایه‌های قابل آموزش و تعداد دوره‌ها

با توجه به شکل ۱۱، افزایش تعداد دوره‌ها و لایه‌های قابل آموزش موجب بهبود عملکرد مدل شد. در ادامه، مدل ResNet-50 بررسی شد. شکل ۱۲ روند آموزش اولیه این مدل را با استفاده از وزن‌های از پیش آموخته شده نشان می‌دهد.




شکل (۱۲) روند آموزش مدل ResNet-50 در حالت اولیه

با توجه به شکل ۱۲، عملکرد اولیه مدل نیازمند بهبود بود؛ بنابراین، در مرحله بعد بخشی از لایه های شبکه برای بازآموزی آزاد شد. شکل ۱۳ روند آموزش ResNet-50 را پس از تغییر تعداد لایه های قابل آموزش نشان می دهد.




شکل (۱۳) روند آموزش داده ها در مدل ResNet 50 پس از تغییر تعداد لایه های آموزش

ا توجه به شکل ۱۳، افزایش تعداد پارامترهای قابل آموزش تغییر چشمگیری در دقت ایجاد نکرد. شکل ۱۴ روند آموزش ResNet-50 را پس از افزایش تعداد دوره ها و تغییر تعداد لایه های قابل آموزش نشان می دهد..




شکل (۱۴) روند آموزش مدل ResNet-50 پس از تغییر تعداد لایه‌ها و دوره‌های آموزشی

با توجه به شکل ۱۴، عملکرد مدل تا حدودی بهبود یافت، اما همچنان نسبت به MobileNetV2 ضعیف‌تر بود. در مرحله بعد، مدل ResNet-101 مورد بررسی قرار گرفت. شکل ۱۵ روند آموزش اولیه این مدل را نشان می‌دهد.




شکل (۱۵) روند آموزش مدل ResNet-101 در حالت اولیه

با توجه به شکل ۱۵، عملکرد اولیه مدل رضایت‌بخش نبود؛ از این رو، تعداد دوره‌های آموزشی افزایش یافت و بخشی از لایه‌ها برای بازآموزی آزاد شدند. شکل ۱۶ روند آموزش ResNet-101 را پس از تغییر تعداد لایه‌های قابل آموزش نشان می‌دهد.




شکل (۱۶) روند آموزش مدل ResNet-101 پس از تغییر تعداد لایه های قابل آموزش

با توجه به شکل ۱۶، تغییر تنظیمات موجب بهبود نسبی روند یادگیری شد. شکل ۱۷ روند آموزش ResNet-101 را پس از افزایش تعداد لایه های قابل آموزش و دوره های آموزشی نشان می دهد.




شکل (۱۷) روند آموزش مدل ResNet-101 پس از تغییر تعداد لایه ها و دوره های آموزشی

با توجه به شکل ۱۷، تغییر تنظیمات آموزشی موجب بهبود عملکرد مدل نسبت به حالت اولیه شد. پس از آن، مدل EfficientNetB7 بررسی شد. شکل ۱۸ روند آموزش اولیه این مدل را نشان می دهد.




شکل (۱۸) روند آموزش مدل EfficientNetB7 در حالت اولیه

با توجه به شکل ۱۸، در تنظیمات اولیه یادگیری مدل محدود بود؛ بنابراین، بخشی از لایه‌ها برای بازآموزی آزاد شدند. شکل ۱۹ روند آموزش EfficientNetB7 را پس از تغییر تعداد لایه‌های قابل آموزش نشان می‌دهد.




شکل (۱۹) روند آموزش مدل EfficientNetB7 پس از تغییر تعداد لایه‌های قابل آموزش

با توجه به شکل ۱۹، آزادسازی بخشی از لایه‌ها موجب بهبود روند یادگیری مدل شد. در نهایت، مدل EfficientNetV2L مورد ارزیابی قرار گرفت. شکل ۲۰ روند آموزش اولیه این مدل را نشان می‌دهد.



شکل (۲۰) روند آموزش مدل EfficientNetV2L در حالت اولیه

در شکل ۲۰، در دوره های ابتدایی روند یادگیری مناسبی مشاهده نشد؛ بنابراین، تعداد دوره ها افزایش یافت و تعداد بیشتری از لایه ها برای بازآموزی آزاد شدند. شکل ۲۱ روند آموزش EfficientNetV2L را پس از تغییر تعداد لایه های و افزایش تعداد دوره ها نشان می دهد.



شکل (۲۱) روند آموزش مدل EfficientNetV2L پس از تغییر تعداد لایه های قابل آموزش و دوره های آموزشی


با توجه به شکل ۲۱، عملکرد مدل نسبت به حالت اولیه بهبود یافت؛ با این حال، در دوره های پایانی نشانه هایی از بیش برآزش (Overfitting) مشاهده شد. با وجود این، این مدل در مقایسه با بسیاری از مدل های مورد بررسی، دقت بالاتری ارائه کرد.

۵. تحلیل یافته ها

ماتریس درهم ریختگی (Confusion Matrix) یکی از روش های متداول برای ارزیابی عملکرد مدل های طبقه بندی، به ویژه در مسائل چند کلاسه است. این ماتریس با مقایسه برچسب های پیش بینی شده با مقادیر واقعی، نتایج مدل را در قالب چهار حالت مثبت صحیح (TP)، منفی صحیح (TN)، مثبت کاذب (FP) و منفی کاذب (FN) بررسی می کند. بر اساس مقادیر حاصل از ماتریس درهم ریختگی، عملکرد مدل ها با استفاده از معیارهای Accuracy، Sensitivity، Specificity، Precision و F-score ارزیابی شد. مقادیر این شاخص ها برای مدل ها و کلاس های مختلف آسیب در جدول ۵ ارائه شده است. معیار دقت (Accuracy) یکی از متداول ترین شاخص های ارزیابی است و نسبت تعداد پیش بینی های صحیح به کل پیش بینی ها را نشان می دهد. این معیار مطابق رابطه (۶) محاسبه می شود.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (۶)$$

هرچه مقدار Accuracy به یک نزدیک تر باشد، میزان پیش‌بینی صحیح مدل بیشتر است. باین حال، برای ارزیابی جامع‌تر عملکرد مدل، به‌ویژه در صورت نامتوازن بودن تعداد نمونه‌های کلاس‌ها، لازم است سایر معیارها از جمله Sensitivity، Specificity، Precision و F-score نیز به‌صورت هم‌زمان مورد توجه قرار گیرند. شکل ۲۲ عملکرد مدل‌های مختلف را بر اساس معیار Accuracy در تشخیص انواع آسیب نشان می‌دهد.




شکل (۲۲) ارزیابی عملکرد مدل‌ها بر اساس معیار Accuracy

با توجه به شکل ۲۲، مقادیر Accuracy مدل‌ها در کلاس‌های مختلف تقریباً در محدوده ۰,۳۱ تا ۰,۶۹ قرار دارد. در مجموع، مدل‌های EfficientNetB7 و EfficientNetV2L عملکرد بهتری در تشخیص برخی کلاس‌ها، به‌ویژه آسیب‌های سطحی و عمیق، داشته‌اند و EfficientNetV2L بالاترین عملکرد را در میان مدل‌های مورد بررسی نشان داده است. معیار حساسیت (Sensitivity) توانایی مدل در شناسایی صحیح نمونه‌های مثبت را نشان می‌دهد و مطابق رابطه (۷) محاسبه می‌شود:

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (۷)$$

این معیار که با عنوان نرخ مثبت صحیح (True Positive Rate) یا Recall نیز شناخته می‌شود، مشخص می‌کند چه نسبتی از نمونه‌های مثبت واقعی به‌درستی توسط مدل شناسایی شده‌اند. شکل ۲۳ مقایسه عملکرد مدل‌ها بر اساس این معیار را نشان می‌دهد.




شکل (۲۳) ارزیابی عملکرد مدل ها بر اساس معیار Sensitivity

با توجه به شکل ۲۳، مقدار Sensitivity مدل ها تقریباً در محدوده ۰,۳۲ تا ۰,۷۰ قرار دارد. مدل EfficientNetV2L با حساسیت حدود ۰,۷۰ بهترین عملکرد را نشان داده و EfficientNetB7 نیز با مقدار حدود ۰,۶۹ در جایگاه بعدی قرار گرفته است. همچنین، در بسیاری از مدل ها حساسیت بالاتری در تشخیص آسیب آینه جانبی مشاهده می شود. معیار ویژگی (Specificity) میزان توانایی مدل در تشخیص صحیح نمونه های منفی را نشان می دهد و مطابق رابطه (۸) محاسبه می شود:

$$\text{Specificity} = \frac{TN}{FP + TN} \quad (۸)$$


این معیار که با عنوان نرخ منفی صحیح (True Negative Rate) نیز شناخته می شود، توانایی مدل را در ایجاد تمایز میان نمونه های متعلق و غیرمتعلق به هر کلاس ارزیابی می کند. شکل ۲۴ عملکرد مدل ها را بر اساس معیار Specificity نشان می دهد.



شکل (۲۴) ارزیابی عملکرد مدل ها بر اساس معیار Specificity

با توجه به شکل ۲۴، مقادیر این معیار تقریباً در محدوده ۰,۳۱ تا ۰,۶۹ قرار دارند. مدل های ResNet-101 و EfficientNetV2L در برخی کلاس ها مقادیر بالاتری از Specificity را نشان داده اند که بیانگر توانایی مناسب تر آن ها در تشخیص صحیح نمونه های منفی است. معیار Precision میزان قابل اعتماد بودن پیش بینی های مثبت مدل را مشخص می کند؛ به عبارت دیگر، نشان می دهد چه نسبتی از نمونه هایی که مدل به عنوان مثبت تشخیص داده است، واقعاً به همان کلاس تعلق دارند. این معیار مطابق رابطه (۹) محاسبه می شود:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (۹)$$




شکل (۲۵) ارزیابی عملکرد مدل‌ها بر اساس معیار Precision

با توجه به شکل ۲۵، مقادیر Precision تقریباً در محدوده ۰,۳۱ تا ۰,۶۷ قرار دارد. در مجموع، EfficientNetV2L با مقدار حدود ۰,۶۷ بالاترین سطح اعتمادپذیری پاسخ‌های مثبت را نشان داده است. همچنین در بسیاری از مدل‌ها، تشخیص تصاویر مربوط به آسیب شیشه از Precision بالاتری برخوردار بوده است. معیار F-score یکی از شاخص‌های جامع ارزیابی مدل‌های طبقه‌بندی است که تعادلی میان Precision و Sensitivity برقرار می‌کند. این معیار بر اساس میانگین هارمونیک این دو شاخص و مطابق رابطه (۱۰) محاسبه می‌شود:

$$F - score = \frac{2}{\left(\frac{1}{Precision} + \frac{1}{Sensitivity}\right)} \quad (10)$$

شکل ۲۶ عملکرد مدل‌های مختلف را بر اساس معیار F-score نشان می‌دهد.



شکل (۲۶) ارزیابی عملکرد مدل‌ها بر اساس معیار F-score

با توجه به شکل ۲۶، مقدار F-score مدل‌ها در مجموع تقریباً از ۰,۳۳ تا ۰,۶۶ متغیر است. مدل EfficientNetV2L با مقدار کلی حدود ۰,۶۶ عملکرد مناسب‌تری نسبت به سایر مدل‌ها داشته است. این نتیجه نشان می‌دهد که این مدل توانسته است تعادل بهتری میان حساسیت و دقت پیش‌بینی‌های مثبت ایجاد کند.

نتیجه گیری

در این پژوهش، قابلیت شبکه های عصبی پیچشی عمیق در شناسایی و طبقه بندی آسیب های خودرو پس از تصادف مورد بررسی قرار گرفت. برای این منظور، هفت معماری از پیش آموزش دیده شامل AlexNet، VGG-19، ResNet-50، ResNet-101، EfficientNetB7، EfficientNetV2L و MobileNetV2 با استفاده از رویکرد انتقال یادگیری بر روی تصاویر واقعی خودروهای آسیب دیده ارزیابی شدند. آسیب های مورد بررسی در شش گروه شامل آسیب سطحی، آسیب عمیق، آسیب آینه جانبی، آسیب شیشه، آسیب لاستیک و آسیب چراغ خودرو طبقه بندی شدند. نتایج حاصل از اجرای مدل ها نشان داد که دقت طبقه بندی در بازه ۵۹ تا ۶۳ درصد قرار دارد و عملکرد هر مدل تا حد زیادی به ویژگی های معماری، نحوه استخراج ویژگی ها، حجم و کیفیت داده های آموزشی و تنظیم پارامترهای یادگیری وابسته است. مقایسه مدل ها نشان داد که استفاده از شبکه های از پیش آموزش دیده و انتقال یادگیری می تواند رویکرد مناسبی برای مسائلی باشد که در آن دسترسی به مجموعه داده های بسیار بزرگ و برچسب گذاری شده محدود است. این روش امکان استفاده از دانش آموخته شده در شبکه های عمیق را فراهم کرده و می تواند فرایند آموزش مدل را نسبت به آموزش شبکه از ابتدا تسهیل کند. با این حال، نتایج به دست آمده نشان می دهد که برای دستیابی به دقت بالاتر، افزایش تعداد و تنوع تصاویر، بهبود کیفیت داده ها، متوازن سازی کلاس ها و تنظیم بهینه پارامترهای آموزشی ضروری است.

از منظر کاربردی، نتایج این پژوهش نشان می دهد که شبکه های عصبی پیچشی از ظرفیت مناسبی برای توسعه سامانه های هوشمند تشخیص اولیه خسارت خودرو در صنعت بیمه برخوردارند. استفاده از چنین سامانه هایی می تواند بخشی از فرایند ارزیابی اولیه خسارت را تسهیل کرده و به کاهش زمان بررسی پرونده ها، تسریع پاسخ گویی به بیمه گذاران و بهبود کارایی فرایندهای مرتبط با ارزیابی خسارت کمک کند. همچنین این مدل ها می توانند به عنوان ابزار پشتیبان تصمیم گیری در کنار کارشناسان خسارت مورد استفاده قرار گیرند و زمینه حرکت به سمت فرایندهای هوشمندتر و داده محورتر در صنعت بیمه را فراهم سازند. در مجموع، نتایج پژوهش بیانگر آن است که به کارگیری یادگیری عمیق و شبکه های عصبی پیچشی در حوزه تشخیص خسارت خودرو، با وجود محدودیت های موجود، از قابلیت توسعه و کاربرد عملی برخوردار است. با گسترش مجموعه داده، بهینه سازی معماری ها و افزودن اطلاعات تکمیلی مانند مدل خودرو، سال ساخت، نوع قطعه آسیب دیده و شرایط حادثه، می توان انتظار داشت مدل های دقیق تر و قابل اعتمادتری برای تشخیص نوع و شدت خسارت و در مراحل بعدی برای پشتیبانی از برآورد هزینه تعمیر توسعه یابند.

پیشنهادهای کاربردی

با توجه به نتایج پژوهش، می توان از مدل های مبتنی بر شبکه های عصبی پیچشی به عنوان ابزار پشتیبان در فرایند ارزیابی اولیه خسارت خودرو در شرکت های بیمه استفاده کرد. توسعه یک سامانه یا اپلیکیشن کاربردی که امکان ارسال تصاویر خودرو توسط بیمه گذار و تشخیص اولیه نوع آسیب را فراهم کند، می تواند موجب کاهش زمان بررسی خسارت، تسریع فرایند رسیدگی به پرونده ها و کاهش بخشی از مراجعات حضوری شود. همچنین، یکپارچه سازی مدل با سامانه های اطلاعاتی شرکت های بیمه و افزودن اطلاعاتی مانند نوع و مدل خودرو، سال ساخت و مشخصات حادثه می تواند زمینه توسعه سامانه های جامع تر ارزیابی خسارت را فراهم کند. چنین سامانه ای می تواند در کنار نظر کارشناسان خسارت به عنوان یک ابزار پشتیبان تصمیم گیری مورد استفاده قرار گیرد.

تحقیقات آتی

در مطالعات آینده پیشنهاد می‌شود با افزایش تعداد و تنوع تصاویر و ایجاد مجموعه داده‌ای متوازن‌تر، عملکرد مدل‌ها در تشخیص انواع خسارت خودرو مجدداً ارزیابی شود. همچنین بررسی روش‌های بهینه‌سازی ابرپارامترهایی نظیر نرخ یادگیری، تعداد دوره‌های آموزش، اندازه دسته و سایر پارامترهای مؤثر بر زمان و دقت آموزش می‌تواند به بهبود عملکرد مدل‌ها کمک کند. توسعه مدل‌هایی برای تشخیص هم‌زمان چند آسیب در یک تصویر، تعیین شدت خسارت و در مراحل بعدی بر آورد هزینه تعمیر نیز از زمینه‌های مهم برای ادامه پژوهش است. مقایسه معماری‌های مورد استفاده با مدل‌های جدیدتر بینایی ماشین و بررسی تأثیر متغیرهایی نظیر مدل خودرو، سال ساخت و شرایط تصویربرداری نیز می‌تواند موضوع پژوهش‌های آتی قرار گیرد.

References

- Albelwi, S., & Mahmood, A. (2017). A framework for designing the architectures of deep convolutional neural networks. *Entropy*, 19(6), 242.
- Amin, S., Hijji, M., Iqbal, R., Harrop, W., & Chang, V. (2019). Fuzzy expert system-based framework for flood management in Saudi Arabia. *Cluster Computing*, 22, 11723–11740.
- Bhandare, A., Bhide, M., Gokhale, P., & Chandavarkar, R. (2016). Applications of convolutional neural networks. *International Journal of Computer Science and Information Technologies*, 7(5), 2206–2215.
- Derrig, R. A. (2002). Insurance fraud. *Journal of Risk and Insurance*, 69(3), 271–287.
- Dorafshan, S., Thomas, R. J., & Maguire, M. (2018). Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete. *Construction and Building Materials*, 186, 1031–1045.
- Eom, H., & Choi, H. (2018). Alpha-pooling for convolutional neural networks. *arXiv Preprint arXiv:1811.03436*.
- Gao, Y., & Mosalam, K. M. (2018). Deep transfer learning for image-based structural damage recognition. *Computer-Aided Civil and Infrastructure Engineering*, 33(9), 748–768.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gopalakrishnan, K. (2018). Deep learning in data-driven pavement image analysis and automated distress detection: A review. *Data*, 3(3), 28.
- Gopalakrishnan, K., Gholami, H., Vidyadharan, A., Choudhary, A., & Agrawal, A. (2018). Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model. *International Journal of Traffic and Transportation Engineering*, 8(1), 1–14.
- Gopalakrishnan, K., Khaitan, S. K., Choudhary, A., & Agrawal, A. (2017). Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection. *Construction and Building Materials*, 157, 322–330.
- Han, J., Pei, J., & Tong, H. (2022). *Data Mining: Concepts and Techniques*. Morgan Kaufmann.
- Harshani, W. R., & Vidanage, K. (2017). Image processing based severity and cost prediction of damages in the vehicle body: A computational intelligence approach. In *2017 National Information Technology Conference (NITC)*. IEEE.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778).
- Kim, H., Kim, H., Hong, Y. W., & Byun, H. (2018). Detecting construction equipment using a region-based fully convolutional network and transfer learning. *Journal of Computing in Civil Engineering*, 32(2), 04017082.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- Kumar, N., Srivastava, J. D., & Bisht, H. (2019). Artificial intelligence in insurance sector. *Journal of the Gujarat Research Society*, 21(7), 79–91.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Li, B., Wang, K. C., Zhang, A., Yang, E., & Wang, G. (2020). Automatic classification of pavement crack using deep convolutional neural network. *International Journal of Pavement Engineering*, 21(4), 457–463.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2017). Hyperband: A novel bandit-based approach to hyperparameter optimization. *Journal of Machine Learning Research*, 18(1), 6765–6816.
- Li, P., Shen, B., & Dong, W. (2018). An anti-fraud system for car insurance claim based on visual evidence. *arXiv Preprint arXiv:1804.11207*.
- Maiano, L., Montuschi, A., Caserio, M., Ferri, E., Kieffer, F., Germanò, C., Baiocco, L., Celsi, L. R., Amerini, I., & Anagnostopoulos, A. (2023). A deep-learning-based antifraud system for car-insurance claims. *Expert Systems with Applications*, 120644.
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics.