

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

^۱ دانشجوی کارشناسی ارشد مهندسی صنایع دانشکدگان فارابی دانشگاه تهران

^۲ نویسنده مسئول: عضو هیئت علمی گروه مهندسی صنایع دانشکدگان فارابی دانشگاه تهران hmohammadi@ut.ac.ir

چکیده

در این مقاله، یک چارچوب یکپارچه برای تخمین خسارت خودرو با استفاده از ابزارهای یادگیری ماشین بر پایه الگوریتم های شبکه های عصبی پیچشی CNN در صنعت بیمه ارائه شده است. هدف از این پژوهش تحلیل و ارزیابی عملکرد شبکه های پیچشی عمیق به دست آمده از شبکه های از پیش تعلیم یافته در تشخیص و دسته بندی شش دسته آسیب سطحی، آسیب عمیق، آسیب آینه جانبی خودرو، آسیب شیشه، آسیب لاستیک و آسیب چراغ ناشی از خودروهای سواری داخلی با استفاده از تصاویر گرفته شده از تلفن همراه است؛ در خصوص مطالعه موردی، جامعه آماری این پژوهش مشتریان بیمه شخص ثالث یک شرکت بیمه در سال ۱۳۹۹ و ۱۴۰۰ می باشد و بعنوان برشی از کل تصاویر خودروهای تصادفی کشور بوده و شامل ۲۰۰۰۰ تصویر خودروهای اشخاص پس از تصادف است که ۴۱۰۰ تصویر به عنوان داده های هدف پژوهش از پایگاه داده سیستم های صدور بیمه نامه های شخص ثالث بیمه مذکور اطلاعات آنها انتخاب و استخراج گردید. نتایج این پژوهش نشان می دهد که سرعت عملکرد مدل ها تا حد زیادی به مشخصه های مدل های از پیش تعلیم یافته بستگی دارد و دقت مدل ها بر اساس الگوریتم هایی مانند AlexNet، VGG-19، ResNet-50، ResNet-101، EfficienetNetB7، EfficienetNetV2L و MobiNetV2 در بازه ۰.۵۹ تا ۰.۶۳ بدست آمده است که بیانگر عملکرد قابل قبول مدل های مبتنی بر شبکه های پیچشی عمیق در تشخیص و ارزیابی آسیب خودرو پس از تصادفات است.

کلمات کلیدی: یادگیری عمیق، پردازش تصویر، شبکه عصبی پیچشی، خسارت خودرو، صنعت بیمه

^۱ fatemeh.sarrami@ut.ac.ir


^۲ hmohammadi@ut.ac.ir

۱- مقدمه

امروزه کسب و کارهای مختلف به دنبال بهینه سازی امور خود با استفاده از فناوری ها و روش های پیشرفته و مدرن هستند. با گسترش فعالیت های تجاری و اقتصادی، صنعت بیمه و امور مربوط به آن همچون تخمین خسارت نیز به سرعت گسترش و توسعه یافته و نیازمند تخمین و پیش بینی خسارت دقیق و جامع است. رشد و توسعه محیط های تجاری، افزایش رقابت در امور بیمه، تولید حجم وسیع داده های مربوط به خسارات و نیاز به پردازش این داده ها و دسترسی به اطلاعات سریع و کامل باعث افزایش حجم و تنوع کارهای صنعت بیمه بخصوص در حوزه برآورد خسارت شده است.

در دنیای واقعی، پس از هر نوع تصادف رانندگی، انجام یک تخمین قابل اعتماد برای تعمیر اولین قدم ضروری، در جهت برگشت وسیله نقلیه به حالت عادی و جاده است. در این راستا، یک تخمین غیردقیق می تواند خسارت جبران ناپذیری را به شرکت های بیمه و شرکت های خدمت دهنده به خودروها وارد کند. از طرف دیگر، در روش های سنتی غالباً تخمین خسارت وابسته به نظرات خبرگی کارشناسان است و این امر مشکلات متعددی را چه به لحاظ سازماندهی این افراد و چه از نظر آموزش و دقت این افراد برای شرکت ها ایجاد کرده است. علاوه بر این، این افراد بار هزینه ای قابل توجهی هم به شرکت های بیمه و ارائه دهنده خدمت به خودرو ایجاد می کند.

در فرآیند تخمین خسارت بایستی اطمینان از اینکه برآورد انجام شده مبلغ کافی برای تعمیر خودرو با استانداردهای لازم را داراست به دست آید. به عنوان مثال اگر قطعه ای از تجهیزات وسیله نقلیه آسیب دیده است، برآورد خسارت انجام شده توسط مدل ارائه شده با برآورد مرکز تعمیرات مجاز کارخانه همخوانی داشته باشد در نتیجه، در تصادفات خودرویی، مشتریان (صاحبان خودروها)، شرکت های بیمه ای، تعمیرگاه ها و شرکت های سرویس دهنده امداد از جمله بازیگران مهم می باشند.



شکل ۱- اولین اقدام پس از تصادفات

مشتری علاقه مند است تا با کمترین هزینه از بیشترین و دقیق ترین سرویس ها بهره مند شود. خدمات دهندگان و تعمیرکاران خودرو نیز به دنبال بیشینه سازی سود خود با ارائه خدمات در یک چارچوب تعریف شده هستند. شرکت های بیمه ای نیز با در نظر گرفتن سود خود تعهد می نمایند که زیان احتمالی یک مشتری را در صورت وقوع یک حادثه در یک دوره زمانی خاص، جبران نماید یا خدمات مشخصی را به وی ارائه دهد. با این روش ریسک های احتمالی مشتریان را کاهش دهد. بنابراین در موضوع خسارت های وارده به خودرو، با بازیگرانی روبرو هستیم که هریک به دنبال منافع خود هستند و سعی بر بهینه سازی آن از دیدگاه خود دارند.

در ارتباط بین بازیگران در مسئله تصادفات خودرویی و خسارات وارده، دو موضوع تخلف و اختلاف نظر بین بازیگران شکل می‌گیرد. به‌طور مثال، بازیگران برای حداکثر سازی سود خود تلاش دارند تا با انجام تخلفاتی چون تصادفات ساختگی، تطمیع کارشناسان برآورد کننده خسارات، صدور صورت‌حساب‌های غیرواقعی و.. سود خود را حداکثر و یا هزینه‌های خود را کاهش دهند. چنین موضوعاتی باعث گسترش فساد اداری و سیستمی در بخش‌های درگیر خواهد شد.

علاوه بر این، برآوردهای غیردقیق و به دور از واقعیات کارشناسان خسارات که می‌تواند ناشی از خصوصیات اخلاقی و رفتاری افراد باشد و از فردی به فرد دیگر نیز متفاوت باشد، می‌تواند باعث اختلاف نظرات جدی میان بازیگران و در نتیجه نارضایتی مشتریان، شکایات متعدد مشتریان، نابسامانی و تغییر شرکت‌های بیمه و خدمات رسان توسط مشتریان شود.

از این‌رو نیاز است تا یک سامانه هوشمندی برای تشخیص وضعیت آسیب‌دیدگی خودرویی طراحی و پیاده‌سازی شود که مسائل و مشکلات برآورد خسارات توسط کارشناسان (مانند خستگی، احساسی بودن، مراودات غیررسمی و..) را نداشته باشد و بتواند قضاوت دقیق، سریع و توجیه‌پذیری نسبت به خسارات وارده خودرویی به دور از هرگونه قضاوت‌ها و گرایش‌های غیرمنطقی انسانی داشته باشد.

هدف از این تحقیق این است که یک رویکرد جدید از تشخیص آسیب بدنه وسیله نقلیه با استفاده از تصاویر دو بعدی ارائه شود. بنابراین هنگامی که بدنه وسیله نقلیه آسیب می‌بیند، بدون نیاز به حضور کارشناس بیمه و انتظار از مشخص شدن وضعیت خودرو، کاربر قادر است نوع خسارت خودروی خود را در کوتاهترین زمان ممکن دریافت نماید. هنگامی که یک تصویر آپلود می‌شود، سیستم تصویر را پردازش کرده و آسیب را شناسایی می‌کند. در نهایت، کاربر با ارسال تصویر، نوع خسارت وارد شده به خودرو را دریافت می‌کند. نتایج تحقیق می‌تواند تعداد فرایندهای طی شده پس از تصادف را کم و بسیاری از آنها را حذف کند؛ در نتیجه زمان صرف شده به طور قابل توجهی کاهش می‌یابد.

در این مقاله، هفت مدل بر اساس شبکه‌های عصبی پیچشی عمیق به روش انتقال یادگیری با استفاده از هفت شبکه از پیش‌تعلیم یافته به منظور انجام و دسته‌بندی آسیب‌های خودروی پس از تصادف مورد ارزیابی قرار داده شده است. برای این منظور شش مجموعه داده تصویری از آسیب خودرو به منظور تعلیم، اعتبارسنجی و آزمایش مدل‌ها آماده شد که در هر یک از مجموعه‌ها به مقدار نامساوی از تصاویر شامل آسیب‌های سطحی، عمیق، آینه جانبی خودرو، شیشه و لاستیک خودرو قرار داده شده است.

برخی تصاویر بدلیل وجود بیش از یک آسیب در آن، به صورت تکراری در کلاسهای دیگر نیز استفاده شده است که این استفاده اشتراکی حداکثر ده الی پانزده درصد کل داده‌ها را شامل می‌شود. هم در این پژوهش از هفت شبکه از پیش‌تعلیم یافته پر کاربرد به منظور ساخت مدل‌های تشخیص آسیب استفاده شد که عبارتند از: VGG-19, ResNet-50, ResNet-101, EfficienNetNetB7, EfficienNetV2L و MobinetV2

۲- مبانی نظری و پیشینه تحقیق

در سال‌های اخیر تمرکز سازمان‌ها بر توسعه سامانه‌های خودکار به منظور برداشت و ارزیابی بهتر اطلاعات بوده و تحقیقات گسترده‌ای در این زمینه انجام شده است. (Han, Pei et al. 2022) حضور در بازار پر تلاطم رقابت، سازمان‌ها را به استفاده از رویکرد نوین جهت نگهداشت مشتریان جاری، شناسایی و جذب مشتریان جدید سوق داده است. (بیگدلی، جباری et al. ۲۰۲۱) در آینده نزدیک، صنعت بیمه یکی از سریع‌ترین صنایع در حال رشد با استفاده از تشخیص تصویر خواهد بود. (Li and Dorai ۲۰۰۷) هر روزه با افزایش تعداد افرادی که رانندگی می‌کنند، تعداد تصادفات و ادعاهای بیمه اتومبیل افزایش یافته است. چرخه عمر ثبت، پردازش و تصمیم‌گیری 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, Larochelle et al. ۲۰۱۲).

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. میدانیم 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 می رود برای دریافت خدمات بیمه درگیر فرایند اداری کار میشوند و برای دریافت خدمات معمول، هزینه های مازاد پرداخت می کنند. با ایجاد بستر شخصی سازی، شرکت های بیمه میتوانند در خدمات متناسب با نیازهای منحصر به فرد کاربران؛ موفق تر عمل کنند و در زمان خود صرفه جویی کنند.

با توجه به گستره ی 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 نزدیکتری نسبت به سایر مقالاتی است که در این شاخه فعالیت میکنند. خلاصه ای از برخی از این مقالات به شرح زیر می باشد:

جاو تنگو و همکاران^۱ (۲۰۱۷) جمعی از تکنیک های مختلف پردازش تصویر مورد استفاده برای تشخیص ترک ها در سازه های مهندسی بررسی شده است و ۵۰ مقاله تحقیقاتی را برای بررسی براساس تشخیص ترک در نظر گرفته است. شکاف های روی سطح بتن یکی از اولین نشانه های تخریب سازه است که برای تعمیر و نگهداری بسیار مهم است و با گذر زمان این ترک گسترش یافته و منجر به آسیب شدید سازه خواهد شد. بازرسی دستی روش قابل قبول برای بازرسی ترک است. ، تشخیص خودکار ترک مبتنی بر تصویر به عنوان جایگزینی پیشنهاد می شود.

سریواستاوا کومارو همکاران^۲ (۲۰۱۹) به کاربردهای یادگیری ماشین در صنعت بیمه پرداخته است. به طور خاص، در این مقاله دامنه و نفوذ بازار AI در خدمات بیمه در صنعت مهمانداری بررسی شده تا بر مشکلات جاری در جهت رضایت بهتر مشتری غلبه کنیم. براساس مفاهیم AI، یک مدل مفهومی توسعه داده شد. مدل مفهومی در نظر دارد رابطه بین AI و موارد استفاده آن در صنعت بیمه را اندازه گیری کند و به تشخیص ادعای کلاهبرداری پرداخته شده است .

سینگ آیار و همکاران^۳ (۲۰۱۹) خودکار سازی مطالبات بیمه اتومبیل با استفاده از تکنیک های یادگیری عمیق بیان میکند. اتوماسیون فرآیند بیمه اتومبیل اهمیت و کاربردهای زیادی دارد که می تواند هم به نفع مشتری و هم به نفع شرکت باشد. در این مقاله، یک سیستم خودکار را پیشنهاد شده که اجزای مختلفی برای مقابله با هر یک از وظایف انجام شده در طول فرآیند ادعا دارد و فرایند آنها را برای کاربر جهت آپلود تصاویر، تجسم پیش بینی ها و همچنین برآورد هزینه تعمیر نشان داده است

^۱ Tong, Zheng, Gao, Jie, Zhang, Haitao

^۲ Srivastava, Jayant

^۳ Singh, Ranjodh, Ayyar, Meghna P

جدول ۱ به طور خلاصه مطالعات پیشین حوزه مورد بررسی این تحقیق را در ابعاد مختلف نشان می دهد.

جدول ۱ _ دسته بندی مقالات مرتبط با این تحقیق

منابع	مطالعه موردی	روش و الگوریتم	ویژگی ها													
			Supervised	Unsupervised	Multivariate	Univariate	Global	Local	Dynamic	Static	Splitting	Merging	Direct	Incremental	Parametric	Non-Parametric
Witten and) (۲۰۰۲Frank	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Kotsiantis,) Zaharakis et al. (۲۰۰۷	مروری	Image .CNN processing, deep learning	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Li and Dorai) (۲۰۰۷	بیمه	- Mask R PANet- .CNN Image processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Pan and Yang) (۲۰۰۹	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
(۲۰۱۰Alpaydın)	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Ciresan, Meier) (۲۰۱۱et al.	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Gorunescu) (۲۰۱۱	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Kantardzic) (۲۰۱۱	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Nejad and) (۲۰۱۱Zakeri	معابر و جاده ای	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Nejad and) (۲۰۱۱Zakeri	تحقیقاتی-معابر و جاده ای برنامه ریزی پویا	Image .CNN processing	×	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Krizhevsky,) Sutskever et al. (۲۰۱۲	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	×	×	✓	×	✓	×
Snoek,) Larochelle et al. (۲۰۱۲	تحقیقاتی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×

Jayawardena) (۲۰۱۳)	خودرو	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Deng and Yu) (۲۰۱۴)	آموزشی	Machine learning	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
(۲۰۱۴Robert)	آموزشی	.CNN ImageNet- Image processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Azar and) Vaidyanathan (۲۰۱۵)	آموزشی	Image processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Domhan,) Springenberg et (۲۰۱۵al.	آموزشی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
LeCun, Bengio) (۲۰۱۵et al.	آموزشی-تحلیلی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Najafabadi,) Villanustre et al. (۲۰۱۵)	آموزشی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
(۲۰۱۵Nielsen)	تحقیقاتی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Young, Rose) (۲۰۱۵et al.	آموزشی-کاربردی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Bhandare,) Bhide et al. (۲۰۱۶)	آموزشی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Goodfellow,) Bengio et al. (۲۰۱۶)	روسازی جاده ای	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Nejad, Karimi) (۲۰۱۶et al.	تحقیقاتی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Albelwi and) (۲۰۱۷Mahmood	جاده ای	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Gopalakrishnan) , Khaitan et al. (۲۰۱۷)	خودروسازی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗
Harshani and) (۲۰۱۷Vidanage	تحقیقاتی	Image .CNN processing	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗	✓	✗

Li, Jamieson et) (۲۰۱۷al.	خودروسازی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Patil, Kulkarni) (۲۰۱۷et al.	تحقیقاتی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Tong, Gao et) (۲۰۱۷al.	تحقیقاتی	convolutional neural network	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Vidal, Bruna et) (۲۰۱۷al.	تحقیقاتی	Image processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Wiatowski and) (۲۰۱۷Bölcskei	نظری-ریاضی	Technique	✓	✓	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
Zhang and) (۲۰۱۷Cheng	ساخت و روسازی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Dorafshan,) Thomas et al. (۲۰۱۸	ساخت و ساز-بتن	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Eom and Choi) (۲۰۱۸	تحقیقاتی- ترکیبی	CNN	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Gao and) (۲۰۱۸Mosalam	عمران-ساختاری	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Gopalakrishnan) (۲۰۱۸	ساخت و روسازی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Gopalakrishnan) , Gholami et al. (۲۰۱۸	حمل و نقل هوایی- غیر نظامی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	×	×	✓	×
Kim, Kim et) (۲۰۱۸al.	ساخت و ساز	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Li, Shen et al.) (۲۰۱۸	بیمه خودرو- کلاهبرداری	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Mohan and) (۲۰۱۸Poobal	عمرانی-جاده ای	Information	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Tong, Gao et) (۲۰۱۸al.	عمرانی-جاده ای	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Zhang, Cheng) (۲۰۱۸et al.	عمرانی-جاده ای	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×

Amin, Hijji et al. (۲۰۱۹)	حوادث طبیعی- سیل	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Kumar,) Srivastava et al. (۲۰۱۹)	بیمه-تحقیقاتی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Qi, Chen et al. (۲۰۱۹)	آموزشی-کاربردی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Riantini,) Subiyanto et al. (۲۰۱۹)	امدادرسانی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Singh, Ayyar) (۲۰۱۹et al.	مطالبات بیمه	Information	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Li, Wang et al. (۲۰۲۰)	عمران	Image .CNN processing	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
Prykaziuk,) Erastov et al. (۲۰۲۰)	بیمه-مروری	Information	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
Ranjbar,) Moghaddasnezh (۲۰۲۰ad et al.	عمران	Information	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
et (سجاد, فریدون (۲۰۲۰al.	عمران	Information	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
et (بیگدلی, جباری (۲۰۲۱al.	عمران-سازه	CAD- Image processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
et (تلخابی, شمسی (۱۴۰۰al.	مواد غذایی-خرما	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Han, Pei et al. (۲۰۲۲)	آموزشی	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
Maiano,) Montuschi et al. (۲۰۲۳)	خودرو	Image .CNN processing	×	×	✓	×	×	✓	✓	×	✓	×	✓	×	×	×
Qaddour and) (۲۰۲۳Siddiqa	خودرو	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×
این تحقیق	آسیب خودرو-بیمه	Image .CNN processing	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓	×

بررسی مقالات موجود در جدول ۱ مرور ادبیات نشان میدهد که:

- ۱- کاربرد دیپ لرنینگ در صنعت خودرو تاکنون به صورت جدی و دقیق با هدف یادگیری خسارت ماشین و انواع آن بررسی نشده است.
- ۲- تحقیقات نشان می دهد مقاله ای با موضوعیت خسارت خودرو و ارزیابی خسارت با ابزارهای یادگیری عمیق ارائه نشده است. در این پژوهش ۶ مورد از آسیب خودرو شامل آسیب سطحی، آسیب عمیق، آسیب آینه جانبی خودرو، آسیب شیشه، آسیب لاستیک و آسیب چراغ مورد بررسی قرار گرفته است و از هفت الگوریتم بینایی ماشین AlexNet، VGG-19، ResNet-101، ResNet-50، EfficienetNetB7، EfficienetNetV2L و MobiNetV2 استفاده شده است.
- ۳- به ندرت در مقالات فوق از داده های واقعی و روز استفاده شده است. مقالاتی که با موضوع متفاوت از این پژوهش و با محوریت دیپ لرنینگ و ابزارهای مرتبط کار شده است صرفاً از یک الی دو ابزار بدون تحلیل عوامل ارزیابی همچون دقت، حساسیت و.. مدل کار شده است. در این پژوهش از داده های یک الی دو سال اخیر استفاده شده است و میتوان اعتماد و اتکای بیشتری به صحت آن با توجه به نتایج آن داشته باشیم.
- ۴- با توجه به مطالعه پژوهش های انجام شده ی پیشین در این زمینه، نوآوری مدل و یکی از نقاط تمایز آن، توجه ویژه به روش های نوین هوش مصنوعی در شرایط کنونی است. از آنجایی که مهم ترین عامل در موفقیت در هنگام روز حادثه، کمک رسانی به موقع و جلوگیری از ایجاد ترافیک جهت تسریع امداد رسانی میباشد این پژوهش میتواند اثرات مثبت مالی و جانی با حداقل سازی زمان ارزیابی تصادف داشته باشد؛ بنابراین در درجه اول زیرسازی مناسب این بستر در کشور و ثانیاً استفاده از ظرفیت علمی و تخصصی در کشور میتواند در تحقق این رویداد بزرگ نقش بسزایی داشته باشد. از نگاه فرایندی، کلیه فعالیت های یک بخش به طور نسبی بر عملکرد سایر بخش ها نیز اثرگذار خواهد بود و نتیجه اثربخشی یک بخش از فرایند، بالطبع باعث انتقال تغییر و تحول به سایر بخش ها خواهد شد. در مجموع میتوان نتیجه گیری کرد که الگوریتم های بینایی ماشین در شرکت های بیمه، شرکت ها خودروسازی که خسارت خودرو از موارد کلیدی آنها محسوب میشود از اهمیت ویژه ای برخوردار است این پژوهش میتواند راه گشای مناسبی برای ورود هوش مصنوعی و یادگیری به این صنایع باشد.

۳- روش شناسی تحقیق

هوش مصنوعی^۱ یک حوزه تحقیقاتی گسترده است که به بررسی و تحقیق درباره طراحی و توسعه سیستم ها و برنامه های کامپیوتری با قابلیت تفکر و عملکرد مشابه انسان می پردازد. هدف اصلی هوش مصنوعی، ایجاد سیستم هایی است که قادر به انجام وظایف هوشمندانه و حل مسایل پیچیده با استفاده از الگوریتم ها و روش های محاسباتی خاص باشند.

یادگیری ماشین^۲ یک زیرمجموعه از هوش مصنوعی است که به کامپیوترها امکان می دهد بدون برنامه ریزی صریح و شفاف، از تجربه و داده های ورودی یاد بگیرند و بهبود کنند. در یادگیری ماشین، الگوریتم ها و مدل های آماری مورد استفاده قرار می گیرند تا بر اساس داده های آموزشی، الگوها و قوانین موجود در داده ها را شناسایی و برازش (دقت کنید برازش و نه پردازش) کنند. سپس با استفاده از این الگوها و قوانین، می توانند پیش بینی ها و تصمیم هایی را در مورد داده های جدید ارائه دهند.

استفاده از یادگیری عمیق در برنامه های تشخیص تصویر بسیار رایج است. یادگیری عمیق، بینایی رایانه را در چند سال گذشته به میزان قابل توجهی بهبود بخشیده و به دقت بالایی رسانده است. تشخیص چهره در گوشی های هوشمند، حالت های خودکار در اتومبیل های خودران و تصویربرداری تشخیصی در موارد مربوط به مراقبت های بهداشتی، همگی به لطف بهبود تکنولوژی تشخیص تصویر، پیشرفت های چشمگیری داشته اند.

^۱ Artificial Intelligence

^۲ Machine Learning

شبکه‌های عصبی از الگوریتم‌هایی استفاده می‌کنند که به صورت لایه بندی شده در کنار یکدیگر قرار دارند. این امر باعث می‌شود که هر الگوریتم به نتایج الگوریتم‌های اطراف خود وابسته باشد. این موضوع، باعث ایجاد فرایندی می‌شود که سعی می‌کند استدلال منطقی انسان‌ها را شبیه سازی کند. برای تشخیص تصویر، از شبکه‌های عصبی کانولوشنی (پیچشی) استفاده می‌شود.

اگر زمان کافی در اختیار شبکه عصبی قرار بگیرد، این شبکه قابلیت‌های یادگیری خود را بهبود می‌بخشد، به شرطی که پیش بینی‌های آن دقیق باشد. آموزش‌های زیادی نیاز است تا کامپیوترها بتوانند پیش بینی‌های خود را درست انجام دهند، زیرا آنها به طور خودکار نمی‌دانند چیزهای مختلف، در واقعیت چه نامی دارند.

یادگیری ماشین به سه شکل اصلی زیر تقسیم می‌شود:

۱. یادگیری نظارت شده^۱ 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.
 ۲. یادگیری بدون نظارت^۲ در این روش، مدل بدون داشتن خروجی‌های متناظر با داده‌ها، آموزش می‌بیند. هدف اصلی در یادگیری بدون نظارت، استخراج الگوها، ساختارها و روابط مخفی در داده‌ها است.
 ۳. یادگیری تقویتی^۳ نیز یک شاخه دیگر از یادگیری ماشین است که بر اساس سیستم‌های مبتنی بر پاداش و جریمه عمل می‌کند. در این روش، عامل (Agent) با تعامل با یک محیط و دریافت پاداش‌ها و جریمه‌ها، تلاش می‌کند رفتاری را یاد بگیرد که بیشترین پاداش را به دست آورد.
- در یادگیری بدون نظارت، داده‌های ورودی بدون برچسب یا خروجی مشخص در اختیار مدل قرار می‌گیرند. هدف اصلی در این روش، استخراج الگوها، ساختارها و روابط مخفی در داده‌ها است. در این حالت، مدل به صورت خودکار بدون هدایت برچسب‌ها یا خروجی‌های صحیح، الگوها و ارتباطات معنایی در داده‌ها را کشف می‌کند.
- یادگیری عمیق^۴ یک شاخه از یادگیری ماشین است که بر پایه ساختار شبکه‌های عصبی مصنوعی^۵ استوار است. این روش، مدل‌سازی قدرتمندی را برای تشخیص الگوها و استخراج ویژگی‌های پیچیده از داده‌ها فراهم می‌کند.
- شبکه‌های عصبی عمیق مبتنی بر مدل‌های 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 [۳۳]

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

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

$$X_k = \psi_k(X_{k-1}W^k) \quad (2)$$

^۱ Supervised Learning

^۲ Unsupervised Learning

^۳ (Reinforcement Learning)

^۴ Deep Learning

^۵ Artificial Neural Networks

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:


$$\phi(X, W^1, W^2, \dots, W^k) = \psi_k(\psi_{k-1}(\dots(\psi_2(\psi_1(XW^1)W^2) \dots)W^{k-1})W^k) \quad (3)$$

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 [۳۳].

$$Y \in R^{N \times C} \quad X \in R^{N \times D}$$

$$\text{Min} \ell(Y, \phi(X, W^1, W^2, \dots, W^k)) + \lambda \Theta(W^1, W^2, \dots, W^k) \quad (4)$$


در رابطه فوق، یک تابع زیان $\ell(Y, \phi)$ از پیش تعیین شده تفاوت بین کلاسهای پیش تعیین شده و کلاس های پیش بینی شده بر اساس رابطه Θ برای جلوگیری از اضافه برازش مدل و λ به عنوان پارامتر تعدیل با مقدار مثبت در نظر گرفته می‌شود. برای اطلاعات بیشتر در مورد ساختار مدل های یادگیری عمیق می‌توان به مراجع [۳۳-۴۳] مراجعه نمود. در شکل ۲ نمایی کلی از ساختار عصبی پیچشی در این پژوهش ارائه شده است.



شکل ۲- 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.

^۱ A Typical Convolutional Neural Network(CNN)



شکل ۳- نحوه ایجاد لایه ترکیب به روش الف: انتخاب بیشینه (max pooling) ب: میانگین (average pooling)

مطابق شکل ۲ لایه کانولوشن^۱، 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^۲ 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.



شکل ۴- کانوال داده ها

لایه مسطح کننده تصاویر^۳ به عنوان مسطح کننده تصاویر نیز شناخته می شود. خروجی های به دست آمده از آخرین لایه در یک بردار مسطح می شوند تا بتوان از آن به عنوان داده های ورودی لایه آینده استفاده کرد. لایه بعدی لایه تماما اتصال^۴ بعد از آنکه تجزیه و تحلیل ویژگی انجام شد و زمان محاسبه فرا رسیده است، این لایه وزنی تصادفی به ورودی ها اختصاص می دهد و برچسب مناسبی را پیش بینی می کند. در نهایت لایه خروجی^۵ آخرین لایه مدل CNN است که حاوی نتایج برچسب های تعیین شده برای طبقه بندی است و یک کلاس را به تصاویر اختصاص می دهد. در شکل ۴ طریقه کانوال داده ها نمایش داده شده است.

شبکه عصبی کانولوشن CNN که گرفتن یک تصویر به عنوان ورودی دریافت می کند و به آن مقدار اختصاص می دهد. در انواع شبکه های عصبی نیاز به پیش پردازش (انجام عملیات به منظور کاهش نویز و مقادیر از دست رفته برای دستیابی به نتایج بهتر است) با این حال شبکه های عصبی کانولوشن نیاز کمتری به پیش پردازش دارد. معماری این

^۱Convolutional layer

^۲ Pooling layer

^۳ input fully connected layer

^۴ fully connected

^۵ output fully connected layer

شبکه ی عصبی به این صورت است می‌تواند ابعاد داده های حاصل از تصویر را کاهش به عبارتی توانایی آموزش شبکه برای درک بهتر پیچیدگی‌های تصویر وجود دارد.

این تحقیق یک پژوهش توسعه ای و کاربردی براساس رویکردهای ماشین لرنینگ و روش های مبتنی بر الگوریتم های یادگیری عمیق است که با استفاده از داده های واقعی دو سال گذشته به تحلیل و یادگیری آنها با هدف تشخیص آسیب خودروهای تصادفی و نوع آسیب پرداخته است. ابتدا پس از جمع آوری دیتاهای مورد نظر، به دو دسته داده های آموزش و تست و با نسبت ۷۰٪ و ۳۰٪ تقسیم بندی شده اند. این داده ها بر اساس ۶ نوع از آسیب های معمول کلاس بندی شده و از الگوریتم های یادگیری جمعی برای تشخیص و پیش بینی نوع خسارت به کار گرفته شده است. همچنین برای ارزیابی و مقایسه عملکرد نتایج بدست آمده، از شاخص هایی نظیر دقت و اعتمادپذیری، همساز وزنی، تمایز، توانایی و حساسیت استفاده شده است.

در این مقاله از روش انتقال یادگیری با بهره گیری از مدل های از پیش تعلیم یافته استفاده کنیم. در این روش از قابلیت یادگیری و استخراج ویژگی های اساسی در شبکه های از پیش تعلیم یافته مطابق جدول ۲ (مشخصات و اطلاعات تکمیلی مربوط به شبکه های از پیش تعلیم یافته) که در این پژوهش مورد بررسی قرار گرفته اند برای تعلیم مجدد شبکه بر اساس داده های جدید استفاده می شود؛ این امر امکان ساخت مدل در زمان کمتر، با تعداد داده های کمتر و با صرف توان پردازشی کمتر را فراهم می آورد.

جدول ۲- مشخصات و اطلاعات مدل های از پیش تعلیم یافته

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

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 اضافه برازش (Overfitting) کاهش می‌یابد؛ همچنین زمان تعلیم مدل هاو توان پردازشی افزایش می‌یابد. در این پژوهش از ۴۱۰۰ تصویر از آسیب خودرو با ابعاد متوسط ۴۳۲۰*۳۲۴۰ پیکسل استفاده شده است.



شکل ۵- نمونه داده های استفاده شده از راست: الف: آسیب عمیق، ب: آسیب آینه جانبی خودرو، ج: آسیب شیشه، د: آسیب لاستیک، ه: آسیب سطحی، و: چراغ خودرو

سپس، ساختار مدل شبکه عصبی عمیق تعریف می شود. این شامل نوع و ترتیب لایه ها، تعداد نورون ها در هر لایه و اتصالات بین لایه ها است.

جدول ۳- داده های استفاده شده در این پژوهش

تعداد داده های استفاده شده در این پژوهش		دسته بندی
عملیات یادگیری		
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


مرحله آموزش مدل شامل ارسال داده ها به مدل، محاسبه خروجی پیش بینی شده توسط مدل، محاسبه خطا بین خروجی پیش بینی شده و مقدار واقعی و استفاده از الگوریتم پس انتشار خطا برای به روز رسانی وزن ها در شبکه است.

این روند تا زمانی که دقت مدل با در نظر گرفتن میزان خطا و کنترل آن، افزایش یابد تکرار شده و ادامه پیدا میکند. به طور معمول تصاویر برداشت شده از کیفیت لازم برای استفاده به عنوان ورودی فرایند ساخت مدل های دسته بندی را ندارند. به مرور توزیع مقادیر پیکسل های تصویر گسترده تر و شدت مقادیر متعادل تر میشود و در نتیجه تصاویری با روشنی و وضوح بالاتری را ایجاد میکند.

در این پژوهش عملکرد مدل های ایجاد شده به روش انتقال یادگیری بر اساس شش شبکه از پیش تعلیم یافته برای تشخیص و دسته بندی انواع آسیب های خودرویی در تصادفات مورد ارزیابی قرار داده شده است. شش الگوریتم استفاده شده در این پژوهش جهت شناسایی عیوب خسارات عبارت اند از: AlexNet, VGG-19, ResNet-50, ResNet-101, EfficienetNetV2L, EfficienetNetB7. همانطور که در جدول ۳ مشاهده میشود، در مجموع ۴۰۶۲ تصویر در روند یادگیری مدل ها استفاده شده است که از این تعداد 3085 تصویر برای تعلیم و 977 تصویر برای

اعتبارسنجی به کار گرفته شده است. ابزار یادگیری این پژوهش با استفاده از زبان برنامه نویسی پایتون و استفاده از کتابخانه های tensorflow, matplotlib, numpy و glob می باشد.

در مرحله ارزیابی مدل، پس از آموزش مدل، عملکرد آن با استفاده از داده های آزمایشی ارزیابی می شود. معیارهایی مانند دقت، صحت و حساسیت و سایر معیارهای تحلیلی برای ارزیابی عملکرد مدل استفاده شده است. در مرحله بررسی و بهبود مدل در صورتی که عملکرد مدل قابل قبول نباشد، ممکن است نیاز به تغییرات و بهبودهایی در ساختار مدل، الگوریتم آموزش یا پارامترهای آموزشی داشته باشید. در این صورت، بررسی و بهبود مدل به منظور بهبود عملکرد آن انجام می شود.



شکل ۶- نمونه ای از روند آموزش داده ها

در این پژوهش همانطور که در شکل ۶ نمایش داده شده است، با بررسی روند تعلیم مدلها میتوان گفت که نرخ خطا و دقت مدلها تقریباً بعد از ۱۰ تا ۱۲ دوره پایدار گشته و فرایند یادگیری مدلها به بالاترین دقت در هر تکرار میرسند. بر این اساس در این پژوهش ۱۵ دوره مناسب به نظر میرسد.

پارامتر مهم دیگری که قبل از شروع عملیات تعلیم مدلها باید تعیین شود، تعداد نمونه ها (داده ها) در هر تکرار است. تعداد نمونه ها در هر تکرار میتواند بین یک تا تعداد داده های تعلیم انتخاب شود. تعداد زیاد نمونه ها در هر تکرار نیازمند سیستم پردازشی قدرتمند است. در این مقاله با توجه به توان پردازشی، تعداد ۱۵ نمونه در هر تکرار در نظر گرفته شده است. تعداد تکرار لازم برای انجام یک دوره یادگیری با استفاده از رابطه ۵ تعیین میشود.

$$i = \frac{N}{n} \quad (5)$$

که در رابطه فوق N تعداد کل داده های تعلیم و n تعداد نمونه در هر تکرار است. با توجه به در نظر گرفتن ۱۵ نمونه در هر تکرار، ۸۰ تکرار برای انجام یک دوره یادگیری متشکل از ۴۱۰۰ نمونه (داده) نیاز است و در مجموع برای انجام ۱۵ دوره یادگیری، ۴۱۰۰ تکرار باید انجام شود. لازم به ذکر است که اگر تعداد تکرار خیلی زیاد باشد منجر به بروز مشکلاتی نظیر اضافه برازش و افزایش زمان پردازش خواهد شد.

نرخ یادگیری و مقدار تکانه پارامترهای دیگری هستند که در نتیجه یادگیری تأثیر داشته و اغلب در مطالعات مختلف به ترتیب ۰.۰۰۱ و ۰.۹ در نظر گرفته میشوند. در این مقاله، پارامترهای تأثیرگذار بر عملیات یادگیری در تمامی مدلهای از پیش تعلیم یافته به صورت یکسان در نظر گرفته شده اند ولی برای مدل ResNet-101 به علت محدودیت توان پردازشی و بالا بودن عمق و تعداد پارامترهای مدل (مطابق جدول ۲) منجر به عدم کفایت فضای حافظه برای انجام عملیات یادگیری میشود.

به همین دلیل تعداد نمونه در هر تکرار مدل ResNet-101 برابر ۱۲ در نظر گرفته شده است. تمامی پردازشها و محاسبات انجام شده در این مقاله با استفاده از یک کامپیوتر شخصی با سیستم اجرایی ۶۴ بیتی با پردازنده گرافیکی NVIDIA GeForce RTX 3060 با حافظه ۱۲ گیگابایتی و با عملیات پردازش تصویر و پیاده سازی یادگیری عمیق در نرم افزار Python 2022 و GoogleColab اجرا شده است. محدودیت های مسئله مورد بررسی عبارتند از:

- سخت افزار و داده: جهت استفاده از الگوریتم های هوش مصنوعی و فراهم کردن داده های آموزشی مورد نیاز مطابق با هدف پژوهش، به سخت افزارهای قدرتمندی احتیاج است که با توجه به میزان پیچیدگی مسائل، به مراتب به هزینه بالایی احتیاج دارند.
- عملکرد مبتنی بر احتمالات: شبکه های عصبی و ماشین ویرن برای یادگیری مسائل مختلف، از مباحث آمار و احتمال استفاده می کنند. به همین جهت نمیتوان صد درصد اطمینان از مدل انتظار داشت و نمیتواند در شرایط حساس، به صورت کاملاً صحیح تصمیم درست برای حل مسئله بگیرد.
- وابستگی به داده: پایه و اساس کار با سیستم های هوشمند شبکه های عصبی، داده است. شبکه های عصبی و بینایی ماشین برای آموزش نیاز به تعداد زیادی داده از موضوع هدف دارند. جمع آوری داده های مورد نیاز و آماده سازی آن ها برای آموزش مدل، نیاز به هزینه های مالی و زمانی بالایی دارد. همچنین داده های فراهم شده ممکن است دارای نویز باشد که بر عملکرد شبکه و مدل تاثیر زیادی داشته باشد.
- تعدد متغیر: متغیرهای زیادی وجود دارند که خارج از کنترل محقق هستند و می توانند موفقیت و دقت را تحت تاثیر قرار دهند.
- کاهش منابع انسانی: با هوشمند سازی سیستم ها و جایگزین کردن آن ها به جای افراد، بسیاری از افراد شغل خود را از دست می دهند و با طبقات منفی روبه رو خواهیم شد.

۴- یافته های تحقیق (بر اساس استفاده از روش های یادگیری عمیق)


پس از انجام فرایند یادگیری مدل ها بر اساس داده های تعلیم و ارزیابی دقت بر اساس داده های آزمون، نتایج به دست آمده از زمان ارزیابی سرعت مدلها در یادگیری و اجرا و دقت مدل ها در تشخیص و دسته بندی آسیب ها به عنوان دو پارامتر اصلی عملکرد مدل ها در ادامه در جدول ۴ ارائه شده است.

جدول ۴- زمان طی شده آموزش برای هر تصویر


مدل	زمان ارزیابی مدل (ثانیه)	زمان پیش پردازش برای هر تصویر (ثانیه)	زمان آموزش مدل (ثانیه)
AlexNet	0/019	0	0/482
VGG-19	0/024	0	0/637
ResNet-50	0/041	0/056	1/944
ResNet-101	0/054	0	3/823
EfficientNetB7	0/061	0	61/85
EfficientNetV2L	0.056	0	64/25
MobilenetV2	0/034	0	0.55

سرعت یادگیری و دسته بندی داده های جدید

همانطور که در جدول ۴ نمایش داده شده است برای ارزیابی سرعت مدلها، زمان طی شده در فرایندهای پیش پردازش تصاویر، یادگیری و ارزیابی مدلها مورد بررسی قرار گرفته است. با توجه به این که عملیات پیش پردازش پیش از تعلیم و ارزیابی مدلها انجام میشود، در شکلهای ۷ و ۸ مقایسه ی سرعت عملکرد مدلها در عملیات یادگیری (پیش پردازش و تعلیم) و عملیات ارزیابی (پیش پردازش و ارزیابی) ارائه شده است.



شکل ۷- مقایسه سرعت مدل ها در عملیات یادگیری



شکل ۸- مقایسه سرعت مدل ها در عملیات ارزیابی

همانطور که مشاهده میشود در عملیات یادگیری بخش ناچیزی از زمان عملیات به پیش پردازش داده ها اختصاص یافته است. از سوی دیگر فرایند پیش پردازش تصاویر در عملیات یادگیری عملکرد مدل ها، بخش قابل توجهی از زمان را به خود اختصاص داده است. مدلهای AlexNet، VGG، MobileNetV2، ResNet-50 با انجام فرایند یادگیری در کمتر از یک ثانیه و انجام عملیات ارزیابی تصاویر جدید در کمتر از ۱/۰ ثانیه، سرعت بالاتری نسبت به سایر مدلها در عملیات یادگیری و ارزیابی داشته اند.


در بین مدلهای ارزیابی شده، مدل AlexNet با صرف زمان ۰/۴۸۲ ثانیه برای هر تصویر در عملیات یادگیری و ۰/۰۱۹ ثانیه به ازای هر تصویر در عملیات ارزیابی، سریعترین عملکرد و مدل EfficientNetV2L با صرف زمان ۶۴/۲۵ و ۰/۰۵۶ ثانیه به ترتیب برای یادگیری و ارزیابی، کندترین عملکرد را داشته است. جدول ۵ ارزیابی عملکرد مدل ها به صورت کلی نمایش داده شده است.

جدول ۵- ارزیابی کلی عملکرد مدل ها

F- score	Precision	Specificity	Sensitivity	Accuracy	class	model
0/315	0/313	0/310	0/315	0/312	آسیب عمیق	AlexNet
0/356	0/356	0/314	0/356	0/328	آسیب آینه جانبی خودرو	
0/328	0/371	0/314	0/369	0/335	آسیب شیشه	
0/312	0/347	0/312	0/347	0/341	آسیب لاستیک	
0/336	0/320	0/335	0/336	0/314	آسیب سطحی	
0/328	0/328	0/320	0/328	0/312	چراغ خودرو	
0/329	0/339	0/318	0/342	0/324	کل	
0/415	0/415	0/412	0/415	0/422	آسیب عمیق	VGG-19
0/456	0/456	0/414	0/456	0/458	آسیب آینه جانبی خودرو	
0/428	0/471	0/414	0/469	0/435	آسیب شیشه	
0/412	0/447	0/412	0/447	0/441	آسیب لاستیک	
0/436	0/420	0/435	0/436	0/414	آسیب سطحی	
0/428	0/428	0/420	0/428	0/412	چراغ خودرو	
0/429	0/440	0/418	0/442	0/430	کل	
0/515	0/515	0/542	0/515	0/512	آسیب عمیق	ResNet-50
0/556	0/556	0/544	0/556	0/528	آسیب آینه جانبی خودرو	
0/528	0/571	0/514	0/539	0/535	آسیب شیشه	
0/512	0/547	0/552	0/547	0/521	آسیب لاستیک	
0/536	0/520	0/535	0/536	0/514	آسیب سطحی	
0/528	0/528	0/530	0/528	0/512	چراغ خودرو	
0/529	0/540	0/536	0/537	0/520	کل	
0/515	0/515	0/512	0/515	0/512	آسیب عمیق	ResNet-101
0/556	0/686	0/514	0/556	0/528	آسیب آینه جانبی خودرو	
0/528	0/671	0/514	0/569	0/535	آسیب شیشه	
0/512	0/547	0/512	0/547	0/541	آسیب لاستیک	
0/536	0/520	0/535	0/536	0/514	آسیب سطحی	
0/528	0/528	0/520	0/528	0/512	چراغ خودرو	
0/529	0/578	0/518	0/542	0/524	کل	
0/585	0/575	0/595	0/515	0/574	آسیب عمیق	EfficientNetB7


0/556	0/556	0/534	0/600	0/685	آسیب آینه جانبی خودرو	
0/584	0/579	0/574	0/569	0/575	آسیب شیشه	
0/565	0/547	0/592	0/597	0/621	آسیب لاستیک	
0/596	0/566	0/585	0/596	0/524	آسیب سطحی	
0/558	0/598	0/540	0/599	0/541	چراغ خودرو	
0/574	0/570	0/570	0/579	0/587	کل	
0/655	0/615	0/612	0/655	0/672	آسیب آینه جانبی خودرو	EfficientNetV2L
0/656	0/656	0/654	0/696	0/666	آسیب آینه بغل	
0/628	0/671	0/674	0/669	0/655	آسیب شیشه	
0/692	0/647	0/642	0/667	0/691	آسیب لاستیک	
0/676	0/620	0/635	0/656	0/684	آسیب سطحی	
0/628	0/648	0/663	0/628	0/692	چراغ خودرو	
0/656	0/643	0/647	0/662	0/677	کل	
0/515	0/505	0/532	0/515	0/512	آسیب عمیق	MobiNetV2
0/556	0/516	0/514	0/526	0/518	آسیب آینه جانبی خودرو	
0/528	0/521	0/514	0/549	0/525	آسیب شیشه	
0/512	0/517	0/512	0/517	0/541	آسیب لاستیک	
0/536	0/520	0/535	0/526	0/514	آسیب سطحی	
0/528	0/528	0/520	0/528	0/512	چراغ خودرو	
0/529	0/518	0/521	0/527	0/520	کل	

در ادامه به بررسی و تحلیل برخی از الگوریتم ها می پردازیم. ابتدا برای شروع از مدل MobileNetV ۲ استفاده میکنیم، در حالی که کلیه لایه ها به جز لایه ی Dense را در حالت trainable-non قرار داده ایم. نتایج در نهایت به صورت زیر به دست آمد.




شکل ۹- روند آموزش داده ها در مدل MobileNetV2

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 میدهیم.



شکل ۱۰- روند آموزش داده ها در مدل MobileNetV2 پس از تغییر تعداد لایه های آموزش


مطابق شکل ۱۰ علی رغم قرار دادن ۵۴ لایه آخر مدل در حالت train باز هم تغییری در مقدار دقت نداریم پس تعداد لایه های قابل آموزش را افزایش میدهیم. اکنون ۲۰ لایه دیگر را به لایه های trainable افزوده و تعداد اپک ها را نیز ۳۰ اپک قرار میدهیم.



شکل ۱۱- روند آموزش داده ها در مدل MobileNetV2 پس از تغییر تعداد لایه ها و اپک


با افزایش تعداد اپک ها و لایه های قابل آموزش در شکل ۱۱ دقت مدل نیز افزایش یافت. اکنون سعی میکنیم تا از مدل‌های دیگری چون ResNet استفاده نماییم.

در این قسمت نتایج مدل ResNet 50 بررسی می شود. برای شروع از یک ResNet ۵۰ استفاده میکنیم در حالی که صرفاً از وزن های قبلی استفاده نماییم و همه لایه ها در حالت trainable-non قرار داشته باشند. تعداد پارامترهای آموزشی این شبکه بیشتر از ۲۳ میلیون ۵۰۰ هزار میباشد که نسبت به شبکه MobileNetV ۲ بیشتر از ۱۰ برابر میباشد. در نهایت نتایج زیر مطابق شکل ۱۲ حاصل شد.




شکل ۱۲- روند آموزش داده ها در مدل ResNet 50

مطابق شکل ۱۳ در حالت بعدی از ۱۷۵ لایه موجود در شبکه ۱۰۰ لایه اول را در حالت trainable-non و بقیه را در حالت train قرار میدهم. در حدودا ۱۹ میلیون پارامتر به حالت آموزشی در می آیند.



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


با توجه به شکل ۱۴ علیرغم افزایش پارامترهای آموزشی تغییر چشمگیری در افزایش دقت مشاهده نمی کنیم. در مرحله بعد تعداد اپک ها را به ۳۰ اپک و لایه های آموزشی را به ۱۰۰ لایه افزایش میدهم.



شکل ۱۴- روند آموزش داده ها در مدل ResNet 50 پس از تغییر تعداد لایه ها و اپک


باز هم اگرچه مقدار دقت تا حدودی بهتر شده با این حال همچنان نسبت به مدل MobileNet ضعیف تر عمل کرده است. در ادامه از مدل ۱۰۱ ResNet استفاده میکنیم.

در شکل ۱۵ مدل ۱۰۱ ResNet بیشتر از ۴۲ میلیون ۵۰۰ هزار پارامتر دارد که مشابه موارد قبل ابتدا هم لایه های آن را در حالت trainable-non قرار میدهیم.




شکل ۱۵- روند آموزش داده ها در مدل ResNet 101

همانطور که در تصویر ۱۵ نیز مشخص است مقدار دقت کمتر از ۵۰ درصد است و چون تعداد کلاس ها ۲ تا است مشخص می شود مدل احتمالاً اصلاً آموزش ندیده است. در حالت بعد ۳۰ اپک و فقط ۱۰۰ لایه اول از ۳۴۵ لایه موجود را در حالت trainable-non قرار میدهیم.




شکل ۱۶- روند آموزش داده ها در مدل ResNet 101 پس از تغییر تعداد لایه های آموزش

با توجه به شکل ۱۷، ۸۰ لایه اول مدل را trainable-non و بقیه را در حالت trainable قرار میدهیم و در ۳۰ اپک اجرا میکنیم.




شکل ۱۷- روند آموزش داده ها در مدل ResNet 101 پس از تغییر تعداد لایه ها و اپک

شبکه EfficientNetB7 دارای ۶۰ میلیون پارامتر میباشد. ابتدا همه پارامترها را در حالت trainable-non قرار داده و مدل را اجرا میکنیم که در شکل ۱۸ نمایش داده شده است.




شکل ۱۸- روند آموزش داده ها در مدل EfficientNetB7

در ادامه ۱۰۰ لایه اول از ۸۱۴ لایه موجود را در حالت trainable-non قرار داده و مدل را مجدداً اجرا میکنیم.




شکل ۱۹- روند آموزش داده ها در مدل **EfficientNetB7** پس از تغییر تعداد لایه های آموزش

با توجه به نمودار در شکل ۱۹ مشاهده میشود که مدل در حالت دوم شروع به آموزش کرده است. شبکه **EfficientNetV2L** دارای ۱۱۷ میلیون پارامتر میباشد که نسبت به شبکه های قبلی تعداد بیشتری است. همانند موارد قبل ابتدا شبکه را در حالت trainable-non اجرا میکنیم.



شکل ۲۰- روند آموزش داده ها در مدل **EfficientNetV2L**

همانطور که در نمودار در شکل ۲۰ نیز مشخص است هیچ آموزشی در ۱۰ اپک انجام نشده است. بنابراین تعداد اپک ها را به ۳۰ و تعداد لایه های trainable-non را از ۱۰۲۸ به ۸۰ کاهش میدهم.



شکل ۲۱- روند آموزش داده ها در مدل EfficientNetV2L پس از تغییر تعداد لایه های آموزش

اگر به نمودار دقت کنیم متوجه خواهیم شد که در اپک های پایانی مدل دچار overfit شده است. با این وجود می بینیم که نسبت به مدل های قبلی دقت بالاتری دارد.

۴-۱- ارزیابی مدل ها


تشکیل ماتریس درهم ریختگی یکی از بهترین روشهای ارزیابی دقت مدل های ایجاد شده برای انجام پیش بینی و دسته بندی به ویژه در مسائلی با بیش از دو دسته است [۳۱]. این ماتریس با مقایسه ی نتایج حاصل از مدل با واقعیت، پاسخ های به دست آمده از مدل ها در هر یک از دسته ها را با چهار حالت ممکن پاسخ مثبت صحیح (TP)، پاسخ منفی صحیح (TN)، پاسخ مثبت غلط (FP) و پاسخ منفی غلط (FN) بررسی میکند.

پس از تعیین اجزای ماتریس درهم ریختگی می توان کارایی و عملکرد مدلها در دسته بندی و تشخیص صحیح آسیب ها را با استفاده از چند معیار اساسی ارزیابی نمود. accuracy, sensitivity, specificity, score-precision و F از جمله پرکاربردترین معیارها در ارزیابی عملکرد و دقت مدلها در مسائل دسته بندی و پیش بینی هستند. در جدول ۵ مقادیر این معیار ها برای هر یک از مدل ها ارائه شده است و این بخش از مقاله به مقایسه عملکرد مدل ها بر اساس معیار های ذکر شده می پردازد.

معیار **Accuracy** این معیار یکی از رایج ترین معیارهای ارزیابی مدل ها به شمار میرود و بر اساس رابطه ۶ یک نمای کلی از میزان دقت مدلها با تعیین نسبت پاسخ های صحیح TP و TN به کل پاسخ ها ارائه میدهد.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

ارزیابی دقت و مقایسه عملکرد مدل ها برای دسته بندی تصاویر در دسته های تعریف شده و همچنین عملکرد کلی مدل ها بر اساس معیار accuracy در شکل ۲۲ ارائه شده است.




شکل ۲۲- ارزیابی عملکرد الگوریتم ها بر اساس معیار Accuracy

همانطور که در این شکل مشاهده می شود، بر اساس این معیار تمامی مدل ها بهترین عملکرد را دسته بندی و تشخیص تصاویر آسیب عمیق دارند و پس از آن بیشترین پاسخ صحیح در تشخیص آسیب سطحی ارائه شده است. همچنین بر اساس این معیار، مدل های EfficientNetB7 و EfficientNetV2L عملکرد بهتری نسبت به سایر مدل ها در تشخیص و دسته بندی تصاویر دارای آسیب سطحی و عمیق دارند. به طور کلی تمامی مدل ها عملکرد مناسبی ارائه داده اند و عملکرد کلی مدل ها بر اساس این معیار در محدوده ۰,۳۱۲ تا ۰,۶۹۲ قرار دارد که بهترین عملکرد مربوط به مدل EfficientNetV2L است و ضعیف ترین عملکرد را مدل AlexNet دارد.

معیار **Sensitivity** این معیار میزان توانایی و حساسیت مدل ها را در انجام دسته بندی صحیح مشخص میکند. مطابق رابطه ۷ این امر با محاسبه نسبت پاسخ های مثبت صحیح به مجموع پاسخهای مثبت صحیح و پاسخهای منفی غلط انجام میشود. این معیار همچنین با نامهای نرخ پاسخ مثبت صحیح و میزان صحت مدل نیز شناخته میشود.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (7)$$



شکل ۲۳- ارزیابی عملکرد الگوریتم ها بر اساس معیار Sensitivity


به عبارت دیگر معیار Sensitivity ، حساسیت و صحت عملکرد مدل ها در مواقعی که باید پاسخ مثبت داشته باشند را ارزیابی می کند. مقایسه حساسیت مدل ها در دسته بندی صحیح تصاویر در شکل ۲۳ ارائه شده است. همانطور که در این شکل مشاهده می شود، مدل های ارزیابی شده در این پژوهش بیشترین حساسیت و صحت را در تشخیص و دسته بندی تصاویر آینه جانبی خودرو دارند و در مواقع وقوع آسیب، عملکرد اغلب مدل ها به غیر از AlexNet و VGG-19 در تشخیص آسیب های عمیق بهتر از آسیب های سطحی است.

ارزیابی متوسط حساسیت مدل ها در تمامی دسته ها و قرارگیری مقادیر در محدوده ۰,۳۱۵ تا ۰,۶۹۶ بیانگر عملکرد خوب مدل های ایجاد شده با تکنیک یادگیری عمیق است و مدل EfficientNetV2L با حساسیت ۰,۶۹۶ بهترین عملکرد را دارد و به عبارت دیگر در مواقعی که باید جواب مثبت بدهد به طور متوسط در ۰,۶۹ درصد موارد به درستی عمل کرده است. همچنین مدل EfficientNetB7 با متوسط حساسیت ۰/۶۸۵ در جایگاه بعدی قرار دارد و در تشخیص تصاویر آسیب سطحی عملکرد بهتری نسبت به مدل ResNet-101 دارد.

معیار **Specificity** مطابق رابطه ۸ این معیار میزان توانایی مدلها در ایجاد تمایز بین دسته ها را با تعیین نسبت پاسخ های منفی صحیح به مجموع پاسخ های مثبت غلط و پاسخهای منفی صحیح مشخص میکند. این معیار مفهومی مشابه sensitivity را برای پاسخهای منفی ارائه میکند و با نام نرخ پاسخ های منفی صحیح نیز شناخته میشود.

$$\text{Specificity} = \frac{TN}{FP + TN} \quad (8)$$

در شکل ۲۴ عملکرد مدل ها در مواقعی که باید پاسخ منفی بدهند، مقایسه و ارزیابی شده است و همانطور که مشاهده می شود در این معیار نیز مشابه سایر معیار ها بهترین عملکرد مدل ها در دسته بندی تصاویر شیشه است و اغلب مدل ها به غیر از ResNet-101 در ارائه پاسخ منفی صحیح برای تصاویر شیشه و آینه جانبی خودرو عملکرد بهتری نسبت به آسیب سطحی دارند.




شکل ۲۴- ارزیابی عملکرد الگوریتم ها بر اساس معیار Specificity

با ارزیابی متوسط این معیار در همه دسته ها برای هر مدل مشخص می شود که مدل های ResNet-101 و EfficientNetV2L به ترتیب با متوسط ۰,۶۸۶ و ۰,۶۷۱ عملکرد بهتری نسبت به سایر مدل ها دارند. همچنین قرارگیری مقادیر این معیار در محدوده ۰,۳۱۰ تا ۰,۶۸۶ و مقایسه آن با معیار Sensitivity می تواند بیانگر عملکرد بهتر مدل ها در ارائه پاسخ منفی نسبت به پاسخ مثبت باشد.

معیار Precision این معیار یکی از پارامترهای مهم در ارزیابی مدل ها است که میزان دقت و اعتماد پذیری پاسخ های مثبت مدل ها را مشخص میکند یا به عبارت دیگر احتمال صحیح بودن پاسخ های مثبت مدل ها را تعیین میکند. این معیار با نام ارزش پیش بینی مثبت نیز شناخته میشود و مطابق رابطه ۹ محاسبه میشود.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (9)$$



شکل ۲۵- ارزیابی عملکرد الگوریتم ها بر اساس معیار Precision


مطابق جدول ۵ عملکرد کلی مدل ها با بررسی متوسط این معیار در تمامی دسته ها در محدوده ۰,۳۱۳ تا ۰,۶۷۱ قرار دارد که بیانگر عملکرد مناسب مدل ها است. به عبارت دیگر با توجه به ارزیابی این معیار می توان با سطح اعتماد بالایی به پاسخ های مثبت

مدل های ایجاد شده اعتماد کرد. همانطور که در شکل ۲۵ مشاهده می شود، پاسخ مثبت مدل ها در تشخیص و دسته بندی تصاویر شیشه دارای بیشترین ارزش (سطح اعتماد) در تمام مدل ها است. همچنین با توجه به این معیار پاسخ های مثبت مدل EfficienetNetV2L با متوسط ۰,۶۷۱ دارای بالاترین ارزش در بین مدل ها است.

معیار **F- score** یکی از جامع ترین معیارهای ارزیابی دقت و عملکرد مدل های دسته بندی و پیش بینی، معیار **F- score** است که مطابق رابطه ۱۰ با محاسبه میانگین همساز وزنی دو معیار **Precision** و **Sensitivity** تعیین میشود.

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

با توجه به شکل ۲۶ بر اساس این معیار که یک دید جامع از عملکرد مدل ها ارائه می دهد، عملکرد اغلب مدل ها در تشخیص و دسته بندی تصاویر آسیب عمیق و سطحی یکسان است و بهترین عملکرد مدل ها در دسته بندی تصاویر سطحی است.



شکل ۲۶- ارزیابی عملکرد الگوریتم ها بر اساس معیار **F- score**

همچنین متوسط عملکرد مدل ها برای دسته های مختلف در محدوده ۰,۹۵۷ تا ۰,۹۸۶ قرار گرفته است که بیانگر توانایی بالای مدل های ایجاد شده با تکنیک یادگیری عمیق در تشخیص خرابی عمیق است.

بر اساس این معیار مشابه سایر معیار ها، مدل های EfficienetNetV2L با متوسط ۰,۶۹۲ عملیات تشخیص و دسته بندی لاستیک را با دقت بالاتری بدست می آورد.

۵- دیدگاه های مدیریتی

۱- این پژوهش به مدیران کمک میکند تا با ایجاد بستر مناسب و امن در حوزه فعالیت سازمان خود و سازمان های همکار، گزارش یکسان و یکپارچه ای را از میزان و نوع خسارت، به تفکیک با توجه به یکسان سازی قیمت ها در کشور داشته باشند.

۲- مدیران میتوانند با توسعه این پژوهش به داده های سریع و صحیح و گزارش های مختلف اعم از تفکیک استان، آسیب، سال، و نوع خودرو دسترسی داشته باشند.

۳- این پژوهش به مدیران و جامعه با کاهش ترافیک، حذف سیستم کاغذی و یدی، افزایش بهره وری، رضایت اجتماعی از سرعت خدمت رسانی، کنترل هزینه های تعمیر و یکپارچگی آن میتواند کمک بسزایی کند.

۶- جمع بندی و نتیجه گیری

تشخیص آسیب و نوع آسیب در خودرو که عمدتاً از برخورد آن بخش به جسم فیزیکی ناشی میشود نقش بسزایی در بخش های مختلف ارگانهایی همانند صنعت بیمه، درمان و... ایفا میکنند. به همین دلیل در این پژوهش از چندین الگوریتم هوشمند برای شناسایی و تشخیص انواع آنها، بر اساس شبکه های عصبی کانولوشنی ارائه شد. بر طبق این روش هوشمند، تصاویر استخراج شده از تصادفات شهری دو سال گذشته، توسط چند معماری عمیق پیشنهادی طبقه بندی و قیاس شدند. این طبقه بندی شامل دسته های تصاویر آسیب سطحی، آسیب عمیق، آینه جانبی خودرو، شیشه خودرو، لاستیک خودرو و چراغ خودرو بود که صحت ۶۱ درصد را به همراه داشت. نقاط قوت این مقاله را میتوان در چهار مورد برشمرد: اول اینکه معماری عمیق پیشنهادی در مقایسه با سایر معماری ها از پیچیدگی منطقی تر و قابلیت پذیرش بالاتری برخوردار است؛ دوماً در عین سادگی منجر به صحت بالاتری نسبت به سایر روش های معرفی شده در مطالعات پیشین و سایر معماری های عمیق معتبر شده است. مورد سوم به زمان اجرای کمتر نسبت به سایر روش ها مربوط میشود. انتظار میرود که استفاده از سیستم سخت افزاری قوی و همچنین افزایش تعداد داده ها با توجه به چارچوب پروژه و محدوده زمان در این پروژه میتواند به تحقق دقت بالاتر کمک شایانی کند. همچنین وارد کردن آیت های مختلف در آن از جمله سال ساخت، هزینه و مدل خودرو در مدیریت این بخش بسیار مفید و موثر خواهد بود.

بخش های اساسی یادگیری هر الگوریتم در بینایی ماشین نظیر تعداد دوره ها، نرخ یادگیری، تعداد تکرار، تعداد پارامترها و... تاثیر بسیار زیادی در زمان یادگیری و کیفیت مدل یادگیری دارند و در اغلب مطالعات به صورت تجربی و با سعی و خطا تعیین می شوند و این نیاز احساس می شود که تحقیقاتی با هدف بهینه سازی این پارامترها صورت گیرد. این تحقیق روشی را پیشنهاد می کند که در آن کاربر می تواند چندین تصویر از یک آسیب از بدنه وسیله نقلیه خود آپلود کند و سیستم پس از تشخیص تصویر، هزینه آسیب را براساس ویژگی های و شرایط وسیله نقلیه با توجه به مبلغ در نظر گرفته شده و یاد دهنده در الگوریتم مربوطه محاسبه کند. در ابتدا، ویژگی های تصویر آسیب استخراج می شوند، سپس یک فرهنگ لغت از کلمات کد با استفاده از الگوریتم مجموعه کلمات بصری ایجاد می شود، سپس ویژگی های استخراج شده در نظر گرفته می شوند و در کلاس های شدت طبقه بندی می شوند. براساس شدت خسارات، به آنها یک هزینه تقریبی با استفاده از سیستم مبتنی بر قانون داده می شود. سیستم کنونی نوع آسیب، شدت و هزینه را به ازای هر آسیب محاسبه می کند و تنها نوع وسیله نقلیه را در نظر می گیرد. بنابراین پیش بینی هزینه ارائه شده توسط سیستم برای یک وسیله نقلیه خاص نیست. برای بهبود دقت هزینه و خاص تر بودن نسبت به یک وسیله نقلیه، ممکن است سال ساخت و یا مدل مورد توجه قرار خواهد گرفت. با اضافه کردن پیشرفت های ذکر شده در بالا، انتظار می رود که رویکرد پیشنهادی قابل اطمینان تر و دقیق تر باشد.

تعداد داده های مورد استفاده برای تعلیم مدل ها از جمله پارامتر های تاثیرگذار در زمان یادگیری و عملکرد مدل ها است و نیاز است که پژوهش هایی با هدف تعیین بهینه ترین تعداد داده برای انجام عملیات یادگیری در کمترین زمان و با بهترین عملکرد انجام شود. با توجه به عملکرد مناسب مدل های ایجاد شده با استفاده از شبکه های پیچشی عمیق، انجام پژوهش هایی به منظور ساخت مدل های بهینه شده برای تشخیص، دسته بندی و ارزیابی شدت انواع آسیب های ماشین و محاسبه هزینه ضروری به نظر می رسد. مقایسه عملکرد شبکه های پیچشی عمیق به کارگرفته شده در این مقاله با روش های دیگر نظیر روش های مبتنی بر شبکه عصبی ساده یا روش های مبتنی بر پردازش تصویر می تواند موضوع مناسبی برای مطالعات آینده باشد. به منظور افزایش کاربرد مدل پس از طراحی مناسب مدل، میتوان اپلیکیشن کاربردی برای استفاده در شرکت های بیمه و خودرو از این مدل ارائه نمود.

- Albelwi, S. and A. Mahmood (2017). "A framework for designing the architectures of deep convolutional neural networks." *Entropy* 19(6): 242.
- Alpaydın, E. (2010). *Introduction to machine learning*, Cambridge, Mass.: MIT Press.
- Amin, S., M. Hijji, R. Iqbal, W. Harrop and V. Chang (2019). "Fuzzy expert system-based framework for flood management in Saudi Arabia." *Cluster Computing* 22: 11723-11740.
- Azar, A. T. and S. Vaidyanathan (2015). *Computational intelligence applications in modeling and control*, Springer.
- Bhandare, A., M. Bhide, P. Gokhale and R. Chandavarkar (2016). "Applications of convolutional neural networks." *International Journal of Computer Science and Information Technologies* 7(5): 2206-2215.
- Ciresan, D. C., U. Meier, J. Masci, L. M. Gambardella and J. Schmidhuber (2011). Flexible, high performance convolutional neural networks for image classification. Twenty-second international joint conference on artificial intelligence, Citeseer.
- Deng, L. and D. Yu (2014). "Deep learning: methods and applications." *Foundations and trends® in signal processing* 7(3-4): 197-387.
- Domhan, T., J. T. Springenberg and F. Hutter (2015). Speeding up automatic hyperparameter optimization of deep neural networks by extrapolation of learning curves. Twenty-fourth international joint conference on artificial intelligence.
- Dorafshan, S., R. J. Thomas and M. Maguire (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. and H. Choi (2018). "Alpha-pooling for convolutional neural networks." *arXiv preprint arXiv:1811.03436*.
- Gao, Y. and K. M. Mosalam (2018). "Deep transfer learning for image-based structural damage recognition." *Computer-Aided Civil and Infrastructure Engineering* 33(9): 748-768.
- Goodfellow, I., Y. Bengio and A. Courville (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., H. Gholami, A. Vidyadharan, A. Choudhary and A. Agrawal (2018). "Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model." *Int. J. Traffic Transp. Eng* 8(1): 1-14.
- Gopalakrishnan, K., S. K. Khaitan, A. Choudhary and A. Agrawal (2017). "Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection." *Construction and building materials* 157: 322-330.

Gorunescu, F. (2011). Data Mining: Concepts, models and techniques, Springer Science & Business Media.

Han, J., J. Pei and H. Tong (2022). Data mining: concepts and techniques, Morgan kaufmann.

Harshani, W. R. and K. Vidanage (2017). Image processing based severity and cost prediction of damages in the vehicle body: A computational intelligence approach. 2017 National Information Technology Conference (NITC), IEEE.

Jayawardena, S. (2013). "Image based automatic vehicle damage detection".

Kantardzic, M. (2011). Data mining: concepts, models, methods, and algorithms, John Wiley & Sons.

Kim, H., H. Kim, Y. W. Hong and H. Byun (2018). "Detecting construction equipment using a region-based fully convolutional network and transfer learning." Journal of computing in Civil Engineering 32(2): 04017082.

Kotsiantis, S. B., I. Zaharakis and P. Pintelas (2007). "Supervised machine learning: A review of classification techniques." Emerging artificial intelligence applications in computer engineering 160(1): 3-24.

Krizhevsky, A., I. Sutskever and G. E. Hinton (2012). "Imagenet classification with deep convolutional neural networks." Advances in neural information processing systems 25.

Kumar, N., J. D. Srivastava and H. Bisht (2019). "Artificial intelligence in insurance sector." Journal of the Gujarat Research Society 21(7): 79-91.

LeCun, Y., Y. Bengio and G. Hinton (2015). "Deep learning." nature 521(7553): 436-444.

Li, B., K. C. Wang, A. Zhang, E. Yang and G. Wang (2020). "Automatic classification of pavement crack using deep convolutional neural network." International Journal of Pavement Engineering 21(4): 457-463.

Li, L., K. Jamieson, G. DeSalvo, A. Rostamizadeh and A. Talwalkar (2017). "Hyperband: A novel bandit-based approach to hyperparameter optimization." The journal of machine learning research 18(1): 6765-6816.

Li, P., B. Shen and W. Dong (2018). "An anti-fraud system for car insurance claim based on visual evidence." arXiv preprint arXiv:1804.11207.

Li, Y. and C. Dorai (2007). Applying image analysis to auto insurance triage: a novel application. 2007 IEEE 9th Workshop on Multimedia Signal Processing, IEEE.

Maiano, L., A. Montuschi, M. Caserio, E. Ferri, F. Kieffer, C. Germanò, L. Baiocco, L. R. Celsi, I. Amerini and A. Anagnostopoulos (2023). "A deep-learning-based antifraud system for car-insurance claims." Expert Systems with Applications: 120644 %@ 120957-124174.

Mohan, A. and S. Poobal (2018). "Crack detection using image processing: A critical review and analysis." alexandria engineering journal 57(2): 787-798.

Najafabadi, M. M., F. Villanustre, T. M. Khoshgoftaar, N. Seliya, R. Wald and E. Muharemagic (2015). "Deep learning applications and challenges in big data analytics."

Journal of big data 2(1): 1-21.

Nejad, F. M., N. Karimi and H. Zakeri (2016). "Automatic image acquisition with knowledge-based approach for multi-directional determination of skid resistance of pavements." *Automation in Construction* 71: 414-429.

Nejad, F. M. and H. Zakeri (2011). "An expert system based on wavelet transform and radon neural network for pavement distress classification." *Expert Systems with Applications* 38(6): 7088-7101.

Nejad, F. M. and H. Zakeri (2011). "An optimum feature extraction method based on wavelet-radon transform and dynamic neural network for pavement distress classification." *Expert Systems with Applications* 38(8): 9442-9460.

Nielsen, M. A. (2015). *Neural networks and deep learning*, Determination press San Francisco, CA, USA.

Pan, S. J. and Q. Yang (2009). "A survey on transfer learning." *IEEE Transactions on knowledge and data engineering* 22(10): 1345-1359.

Patil, K., M. Kulkarni, A. Sriraman and S. Karande (2017). Deep learning based car damage classification. 2017 16th IEEE international conference on machine learning and applications (ICMLA), IEEE.

Prykaziuk, N., V. Erastov and O. Lobova (2020). "PERSPECTIVES OF IMAGE RECOGNITION UTILIZATION IN INSURANCE." *MODERN APPROACHES TO KNOWLEDGE MANAGEMENT DEVELOPMENT*: 335.

Qaddour, J. and S. A. Siddiqa (2023). "Automatic damaged vehicle estimator using enhanced deep learning algorithm." *Intelligent Systems with Applications* 18: 200192 %@ 202667-203053.

Qi, X., G. Chen, Y. Li, X. Cheng and C. Li (2019). "Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives." *Engineering* 5(4): 721-729.

Ranjbar, S., F. Moghaddasnezhad and H. ZAKERI (2020). "Pavement cracks detection and classification using deep convolutional networks." *Amirkabir Journal of Civil Engineering* 52(9): 2255-2278.

Riantini, R., L. Subiyanto and Adianto (2019). "Easolas-LSA: an expert system for determining number of life-saving appliances based on requirement of International Convention for The Safety of Life At Sea." *WMU Journal of Maritime Affairs* 18(3): 495-507.

Robert, C. (2014). *Machine learning, a probabilistic perspective*, Taylor & Francis.

Singh, R., M. P. Ayyar, T. V. S. Pavan, S. Gosain and R. R. Shah (2019). Automating car insurance claims using deep learning techniques. 2019 IEEE Fifth International Conference on Multimedia Big Data (BigMM), IEEE.

Snoek, J., H. Larochelle and R. P. Adams (2012). "Practical bayesian optimization of machine learning algorithms." *Advances in neural information processing systems* 25.

Tong, Z., J. Gao, Z. Han and Z. Wang (2018). "Recognition of asphalt pavement crack length using deep convolutional neural networks." *Road Materials and Pavement*

Design 19(6): 1334-1349.

Tong, Z., J. Gao and H. Zhang (2017). "Innovation for evaluating aggregate angularity based upon 3D convolutional neural network." Construction and Building Materials 155: 919-929.

Vidal, R., J. Bruna, R. Giryes and S. Soatto (2017). "Mathematics of deep learning." arXiv preprint arXiv:1712.04741.

Wiatowski, T. and H. Bölcskei (2017). "A mathematical theory of deep convolutional neural networks for feature extraction." IEEE Transactions on Information Theory 64(3): 1845-1866.

Witten, I. H. and E. Frank (2002). "Data mining: practical machine learning tools and techniques with Java implementations." Acm Sigmod Record 31(1): 76-77.

Young, S. R., D. C. Rose, T. P. Karnowski, S.-H. Lim and R. M. Patton (2015). Optimizing deep learning hyper-parameters through an evolutionary algorithm. Proceedings of the workshop on machine learning in high-performance computing environments.

Zhang, K. and H. Cheng (2017). A novel pavement crack detection approach using pre-selection based on transfer learning. Image and Graphics: 9th International Conference, ICIG 2017, Shanghai, China, September 13-15, 2017, Revised Selected Papers, Part I 9, Springer.

Zhang, K., H. Cheng and B. Zhang (2018). "Unified approach to pavement crack and sealed crack detection using preclassification based on transfer learning." Journal of Computing in Civil Engineering 32(2): 04018001.

بیگدلی، جباری، حامد **and** شجاعی (۲۰۲۱). "یک روش هوشمند برای طبقه بندی ترک در سازه های بتنی بر اساس شبکه های عصبی عمیق." نشریه مهندسی عمران امیرکبیر ۵۳(۸): ۳۲۰۱-۳۲۲۰.

تلخابی، م.، م. شمسی **and** م. آقایی (۱۴۰۰). تشخیص و طبقه بندی میوه ها با استفاده از یادگیری عمیق (مورد مطالعه گیاه خرما). پنجمین کنفرانس ملی کامپیوتر، فناوری اطلاعات و کاربردهای هوش مصنوعی.

سجاد، ر.، م. ن. فریدون **and** ذ. حمزه (۲۰۲۰). "تشخیص و دسته بندی ترک های روسازی با استفاده از شبکه های پیچشی عمیق."