



تشخیص و دسته‌بندی ترک‌های روسازی با استفاده از شبکه‌های پیچشی عمیق

سجاد رنجبر، فریدون مقدس نژاد*، حمزه ذاکری

دانشگاه صنعتی امیرکبیر، تهران، ایران

تاریخچه داوری:

دریافت: ۱۳۹۸-۰۱-۲۴

بازنگری: ۱۳۹۸-۰۲-۲۲

پذیرش: ۱۳۹۸-۰۳-۰۲

راهن آنلاین: ۱۳۹۸-۰۳-۲۷

کلمات کلیدی:

یادگیری عمیق

انتقال یادگیری

ترک خوردگی روسازی

تشخیص

دسته‌بندی

خلاصه: ارزیابی اطلاعات روسازی یکی از مهم ترین گام‌های پیاده سازی سامانه مدیریت روسازی است و سالانه تلاش‌های گسترده‌ای به منظور افزایش کارایی این سامانه با استفاده از فناوری‌های جدید انجام شده است. در سال‌های اخیر تمکن سازمان‌ها بر توسعه سامانه‌های خودکار به منظور برداشت و ارزیابی بهتر اطلاعات روسازی بوده و تحقیقات گسترده‌ای در این زمینه انجام شده است. دانش داده کاوی و یادگیری ماشین با هدف بهره‌گیری از داده‌های موجود برای ساخت سامانه‌های هوشمند از جمله جدیدترین زمینه‌های تحقیقاتی در علوم مختلف نظری پزشکی، مهندسی، اقتصادی است و نتایج سیار خوبی از به کارگیری این دانش‌ها بدست آمده است. در زمینه مدیریت روسازی تحقیقات متعددی با هدف به کارگیری یادگیری ماشین به ویژه در ارزیابی خرابی‌های روسازی انجام شده است و نتایج این تحقیقات نشان می‌دهد که روش‌های مبتنی بر داده کاوی و هوش مصنوعی، ابزارهای قدرتمندی در ساخت سامانه‌های خودکار و هوشمند هستند. در این مقاله ضمن تشریح مفاهیم تئوری، تلاش شده است که مدل‌هایی با هدف تشخیص و دسته‌بندی خرابی ترک خوردگی روسازی با استفاده از شبکه‌های پیچشی عمیق و به کارگیری روش انتقال یادگیری ایجاد شود و عملکرد آن‌ها از نظر دقت و سرعت یادگیری و اجرا مورد ارزیابی قرار گیرد. نتایج این پژوهش نشان می‌دهد که سرعت عملکرد مدل‌ها تا حد زیادی به مشخصه‌های مدل‌های از پیش تعیین یافته بستگی دارد و دقت مدل‌ها بر اساس معیارهای مختلف (accuracy، sensitivity، F-score...) در بازه ۰/۹۴ تا ۰/۹۹ است که بیانگر عملکرد خوب مدل‌های مبتنی بر شبکه‌های پیچشی عمیق در تشخیص و ارزیابی خرابی‌های روسازی نظیر ترک خوردگی است.

۱- مقدمه

به منظور بیان اهمیت بالای مدیریت، تعمیر و نگهداری شبکه راه‌ها می‌توان به گزارش انجمن مهندسان آمریکا (ASCE^۱) اشاره نمود که بر اساس آن به ازای صرف یک دلار برای بهبود شرایط زیرساخت‌های راه، ۵/۲ دلار بازگشت سرمایه از طریق کاهش مصرف سوخت و آلودگی ناشی از آن، کاهش هزینه‌های نگهداری وسایل نقلیه، افزایش ایمنی و کاهش هزینه نگهداری راه‌ها حاصل می‌شود^[۵]. سامانه مدیریت روسازی راه‌ها از بخش‌های بسیار مهم مدیریت و تعمیر و نگهداری راه‌ها بوده و نقش مهمی در بهبود شرایط

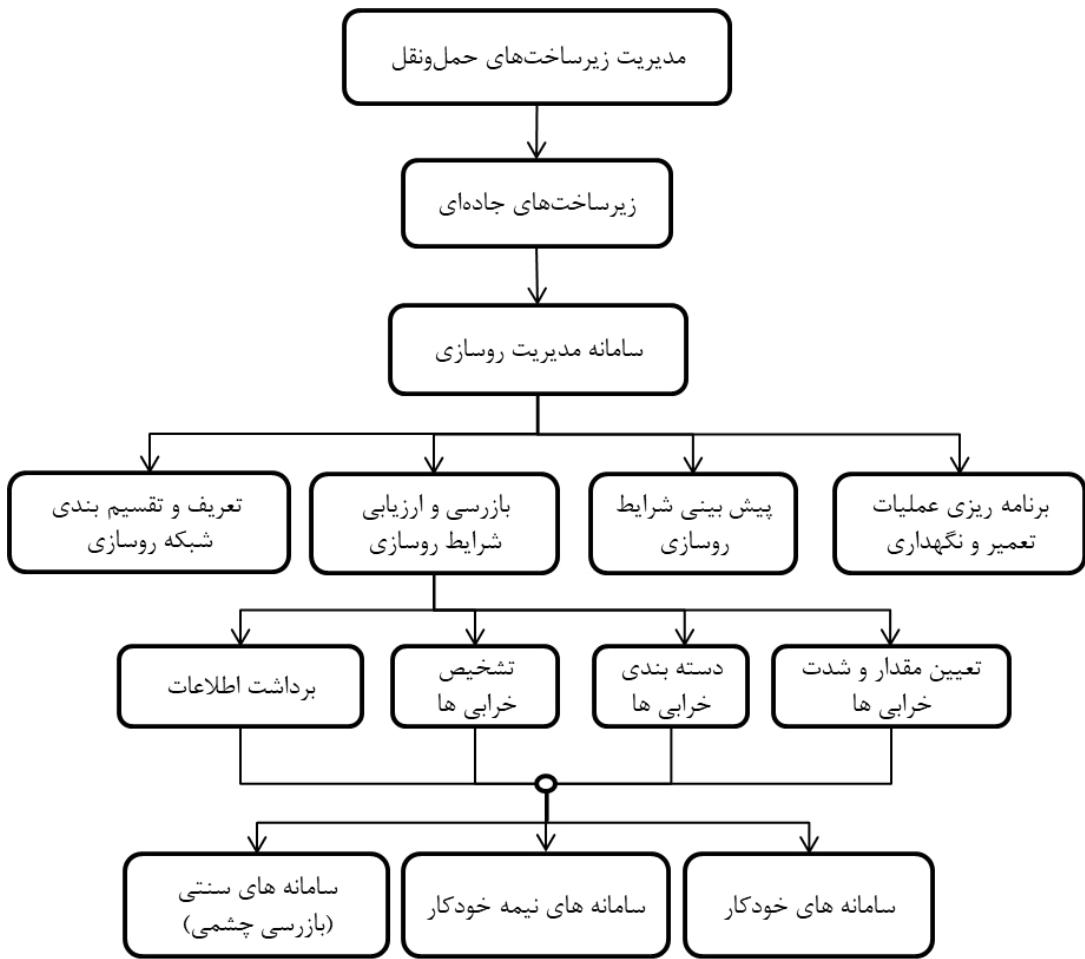
امروزه نقش اساسی زیرساخت‌های حمل و نقل در زندگی بشر و توسعه اقتصادی کشورها، بر اهمیت توسعه و مدیریت زیرساخت‌های حمل و نقل افزوده است. راه‌ها بخش قابل توجهی از زیرساخت‌های حمل و نقل را تشکیل می‌دهند و هر ساله بخش قابل توجهی از نیاز بشر به جایه‌جایی کالا و انسان بر بستر راه‌ها مرتفع می‌گردد. توسعه و مدیریت صحیح شبکه راه‌ها با توجه به مواردی نظیر کاهش زمان سفر و آلودگی ناشی از وسایل نقلیه، کاهش هزینه‌های استهلاکی و مصرفی وسایل نقلیه و افزایش ایمنی، تأثیر مستقیم بر زندگی روزمره

۱ American Society of Civil Engineers

* نویسنده عهده‌دار مکاتبات: moghadas@aut.ac.ir@aut.ac.ir

حقوق مؤلفین به نویسنده‌گان و حقوق ناشر به انتشارات دانشگاه امیرکبیر داده شده است. این مقاله تحت لیسانس آفیرینندگی مردمی (Creative Commons License) در دسترس شما قرار گرفته است. برای جزئیات این لیسانس، از آدرس <https://www.creativecommons.org/licenses/by-nc/4.0/legalcode> دیدن فرمائید.





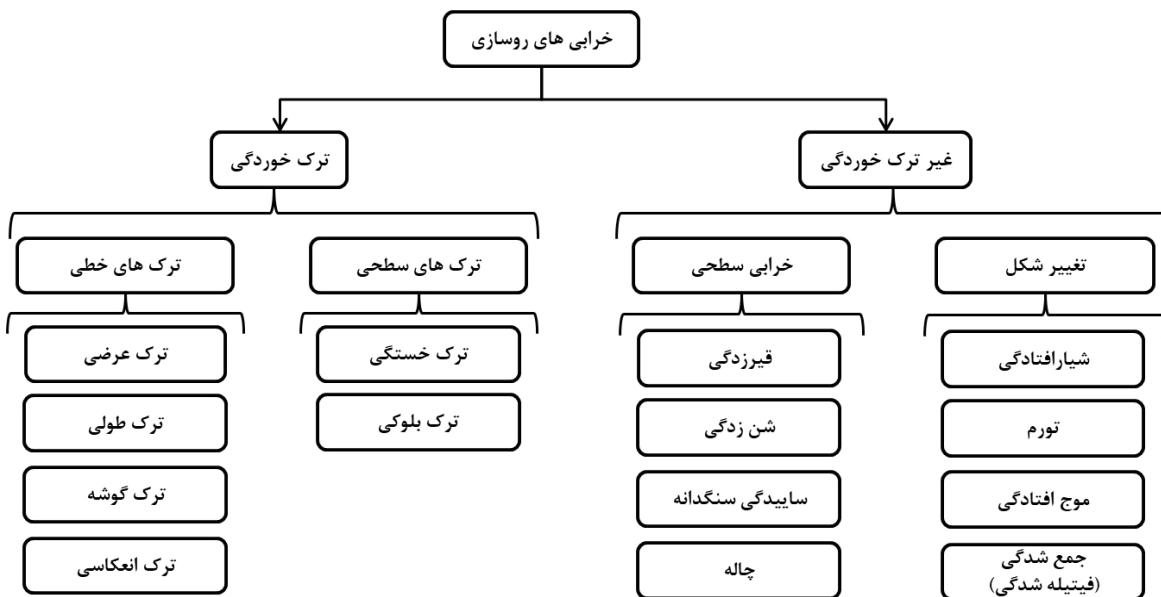
شکل ۱. بازرسی و ارزیابی شرایط روسازی
Fig. 1. Pavement condition evaluation

روسانی مختلف، بازرسی و ارزیابی اطلاعات روسازی به سه روش سنتی، نیمه خودکار و خودکار انجام می‌شود. اما با توجه به معایب روش‌های سنتی نظیر زمان بر بودن، هزینه‌های بالا، غیر قابل اعتماد بودن نتایج، نیاز به حضور کارکنان در جاده، ایجاد اخلال در شرایط ترافیکی مسیر، شرایط کاری پر مخاطره و عدم امکان برداشت اطلاعات در شرایط آب و هوایی نامساعد و همچنین معايب روش‌های نیمه خودکار نظیر غیر قابل اعتماد بودن و متکی به نظر فرد بودن نتایج، زمان بر بودن روند برداشت و ارزیابی اطلاعات، اکثریت وزارت‌خانه‌ها و سازمان‌های مجری سامانه مدیریت روسازی روی توسعه سامانه‌های خودکار برداشت و ارزیابی اطلاعات روسازی متمرکز شده‌اند [۷-۱۰]. در این راستا در سال‌های اخیر، تحقیقات گسترده‌ای به منظور به کارگیری فناوری‌های مختلف برای برداشت و ارزیابی خودکار شرایط روسازی انجام شده است که از پرکاربردترین فناوری‌های به

بهره‌برداری از شبکه راه‌ها دارد. سامانه مدیریت روسازی از پنج بخش اصلی تشکیل شده است که عبارت‌اند از [۶]:

- تعریف شاخه‌ها و قطعات در شبکه روسازی
 - بازرسی و برداشت شرایط روسازی
 - ارزیابی شرایط روسازی
 - پیش‌بینی و آنالیز شرایط روسازی در آینده
 - برنامه‌ریزی برای انجام عملیات تعمیر و نگهداری
- یک سامانه مدیریت روسازی کارا به انجام مناسب‌ترین عملیات تعمیر و نگهداری در بهترین زمان و بهینه‌ترین هزینه اجرایی می‌انجامد که این هدف بدون داشتن اطلاعات کافی از شرایط روسازی میسر نخواهد بود. این موضوع اهمیت بخش بازرسی و برداشت اطلاعات روسازی را مشخص می‌کند [۶].

همانطور که در شکل ۱ مشاهده می‌شود، در سامانه‌های مدیریت



شکل ۲. خرابی های روسازی [۶]
Fig. 2. Pavement distresses

روش‌های یادگیری ماشین کشف و استخراج مشخصه‌ها و قوانین از مجموعه داده‌ها به صورت خودکار انجام می‌شود [۳۶-۳۸]. روش‌های یادگیری عمیق بر پایه اصول شبکه عصبی^۴ استوار است و شبکه‌های عصبی پیچشی یا همگشتی (CNN^۵) از جمله مشهورترین شبکه‌های مبتنی بر یادگیری عمیق هستند که کاربرد گسترده‌ای در استخراج خودکار قوانین و مشخصه‌ها از انواع داده‌ها نظیر متن، تصویر و فیلم دارد [۳۹، ۴۰]. در سال‌های اخیر تحقیقات زیادی با هدف تشخیص و ارزیابی خرابی‌های روسازی با تکیه بر مدل‌های تهیه شده بر اساس CNN انجام شده است. خرابی‌های رایج روسازی را مطابق شکل ۲ می‌توان به دو دسته خرابی‌های شامل ترک خوردگی و خرابی‌های غیر ترک خوردگی تقسیم نمود. ترک خوردگی یکی از متداول‌ترین خرابی‌های روسازی بوده که حجم قابل توجهی از تلاش‌های محققان به منظور ایجاد سامانه‌های خودکار تشخیص خرابی را به خود معطوف کرده است [۴۱-۴۳]. همچنین مطابق شکل ۲ خرابی‌های شامل ترک خوردگی را می‌توان به دو دسته ترک‌های خطی^۶ و ترک‌های سطحی^۷ یا الگودار تقسیم نمود.

در این مقاله، هشت مدل بر اساس شبکه‌های عصبی پیچشی عمیق به روش انتقال یادگیری با استفاده از هشت شبکه از پیش

کارگرفته شده می‌توان به سامانه‌های مبتنی بر دریافت و پردازش تصاویر دو بعدی [۱۱-۱۴]، سامانه‌های برداشت و ارزیابی سه بعدی سطح روسازی [۱۵-۱۸]، سامانه‌های مبتنی بر فناوری رادر [۱۹-۲۱]، سامانه‌های مبتنی بر سنجش شتاب [۲۲-۲۴]، سامانه‌های مبتنی بر فناوری مافوق صوت [۲۵-۲۷]، سامانه‌های ترکیبی [۲۱، ۲۸، ۲۹] اشاره نمود.

از سوی دیگر دانش داده‌کاوی با توجه به رشد توان پردازشی کامپیوترها، سامانه‌های ذخیره‌سازی داده‌ها و حجم انبوه داده‌های برداشت شده در سال‌های گذشته، در بسیاری از زمینه‌های علوم مهندسی، پژوهشی، کسب و کار و ... مورد توجه قرار گرفته است [۳۰، ۳۱] و در این راستا روش‌های مبتنی بر یادگیری ماشین^۸ به منظور پیاده‌سازی اهداف مختلف داده‌کاوی نظیر دسته بندی، تخمین، پیش‌بینی، خوشبندی و ... به کار گرفته می‌شوند و سامانه‌های ساخته شده بر اساس دانش یادگیری ماشین به دنبال استخراج ویژگی‌ها و قوانین^۹ از مجموعه داده‌ها برای استفاده به منظور تصمیم‌گیری بهتر بر اساس داده‌های آینده هستند [۳۲-۳۵].

از پرکاربردترین روش‌های پیاده‌سازی یادگیری ماشین می‌توان به روش یادگیری عمیق^{۱۰} اشاره نمود که در این روش برخلاف سایر

۴ Neural Network

۵ Convolutional Neural Network

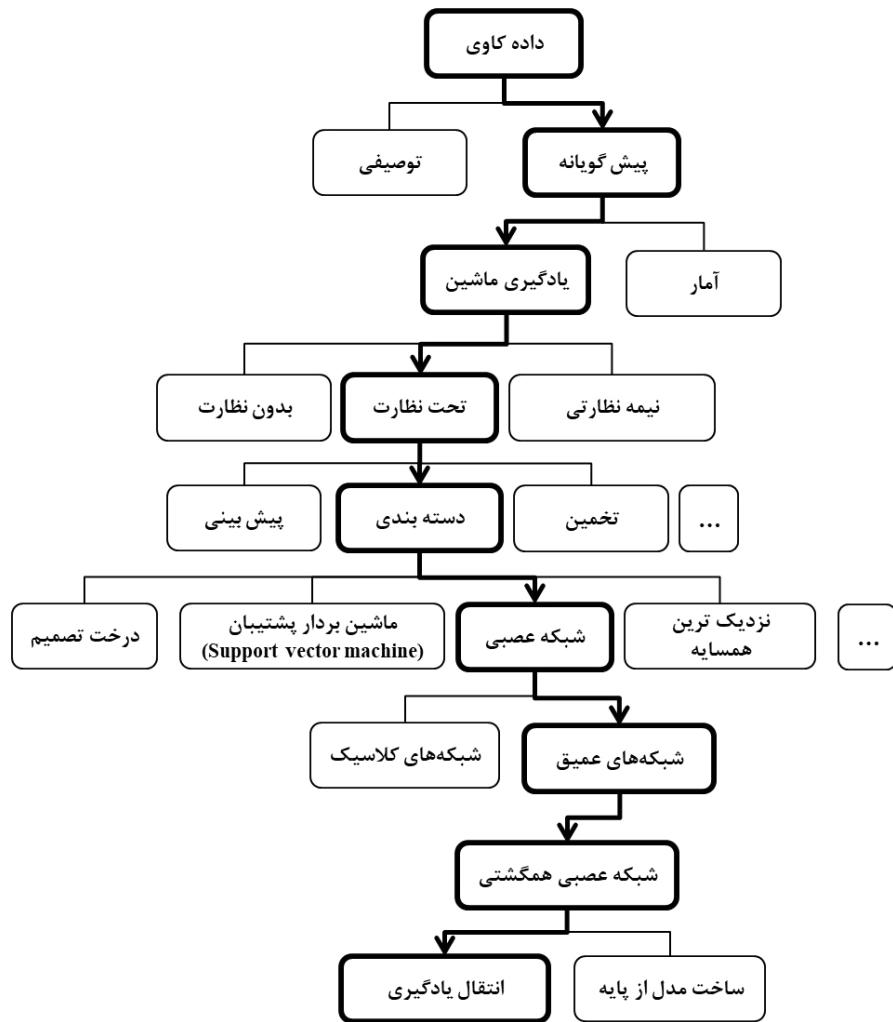
۶ Linear Cracking

۷ Surface Cracking

۱ Machine Learning

۲ Rules

۳ Deep Learning



شکل ۳. چارچوب بهره‌گیری از مفاهیم تئوری
Fig. 3. The framework of applying theoretical concepts

دسته خرابی ترک خوردگی خطی و سطحی است. سازماندهی بخش‌های بعدی مقاله به این صورت است که در بخش دوم مفاهیم تئوری به کارگرفته شده در انجام پژوهش تشرییح می‌شوند. بخش سوم نحوه انجام انجام پژوهش را توضیح می‌دهد و در بخش چهارم نتایج به دست آمده بررسی خواهد شد. در نهایت جمع‌بندی مطالب ارائه شده در این پژوهش در بخش پنجم انجام می‌شود و پیشنهاداتی برای انجام مطالعات آینده ارائه می‌گردد.

۲- مفاهیم تئوری

همانطور که در شکل ۳ چارچوب و روند بهره‌گیری از روش‌ها و مفاهیم مورد استفاده در این پژوهش نمایش داده شده است، در این بخش توضیحاتی پیرامون مفاهیم تئوری هریک از روش‌های به کار

تعلیم یافته^۱ به منظور انجام دسته‌بندی و تشخیص ترک‌های روسازی مورد ارزیابی قرار داده شده است. برای این منظور سه مجموعه داده تصویری از خرابی ترک خوردگی روسازی به منظور تعلیم، اعتبارسنجی و آزمایش مدل‌ها آمده شد که در هر یک از مجموعه‌ها به مقدار مساوی از تصاویر شامل ترک‌های خطی، سطحی و تصاویر بدون ترک خوردگی قرار داده شده است. در این پژوهش از هشت شبکه از پیش تعلیم یافته پر کاربرد به منظور ساخت مدل‌های تشخیص خرابی استفاده شد که عبارتند از: ResNet-18، ResNet-50، DenseNet-201، ResNet-101، ResNet-50

مقاله ارزیابی و مقایسه عملکرد شبکه‌های پیچشی عمیق به دست آمده از شبکه‌های از پیش تعلیم یافته در تشخیص و دسته‌بندی دو

1 Pre-trained Convolutional Neural Network

به سه صورت یادگیری تحت نظارت^۱، بدون نظارت^۲ و نیمه نظارتی^۳ می‌تواند انجام شود[۴۸، ۴۷، ۳۴-۳۲] که در این پژوهش از یادگیری تحت نظارت استفاده شده است. این نوع یادگیری برای انجام برخی از وظایف نظری دسته بندی، پیش‌بینی و تخمین کاربرد زیادی دارد. در این دسته از روش‌های یادگیری ماشین، عملیات یادگیری روی داده‌های ورودی بر اساس داده‌های خروجی شناخته شده، صورت می‌گیرد[۳۵، ۳۳-۴۹].

۲-۲- یادگیری عمیق

یادگیری عمیق یکی از پرکاربرد ترین تکنیک‌های مورد استفاده در یادگیری ماشین است که بر پایه شبکه‌های عصبی استوار است. ساختار مدل‌های یادگیری عمیق مشکل از چند لایه خلاصه‌سازی داده‌ها به منظور استخراج الگوها و ویژگی‌های مورد توجه در داده‌ها است. در این ساختار خلاصه‌ای از داده‌ها در یک لایه به لایه بعد با سطح خلاصه‌سازی بالاتر منتقل می‌شود. ویژگی متمایز کننده یادگیری عمیق از سایر تکنیک‌های یادگیری ماشین، توانایی استخراج خودکار الگوهای مهم از داده‌ها است[۳۲، ۳۷، ۵۰، ۵۱].

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 داده‌های ورودی را به صورت $X \in \mathbb{R}^{N \times D}$ فرض نمود که هر ردیف از X یک داده با بعد D مثل تصاویر خاکستری با D پیکسل است و N تعداد نمونه‌ها آموزشی شبکه است. در این شبکه W^k به صورت ماتریسی برای k انتقال خطی از لایه -1 به مرحله دیگر خلاصه‌سازی در لایه k تعریف می‌شود[۵۲].

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

در مرحله بعد، یکتابع غیر خطی (ψ_k) برای ایجاد لایه k ام مورد استفاده قرار می‌گیرد.

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

این تابع غیر خطی می‌توان به اشکال مختلفی نظری تابع $\tanh(x)$ یا $(1 + e^{-x})^{-1}$ وغیره تعریف و به کار گرفته شود. با

گرفته شده در مقاله ارائه خواهد شد. همچنین اطلاعاتی در مورد نحوه آماده‌سازی و افزایش میزان وضوح و کیفیت تصاویر ارائه شده است.

همانطور که در شکل ۳ مشاهده می‌شود، در این پژوهش به منظور تشخیص و دسته بندی ترک‌های روسازی از دانش داده کاوی پیش‌گویانه مبتنی بر یادگیری ماشین استفاده شده است و در یادگیری ماشین، روش‌های مبتنی بر شبکه عصبی به عنوان یکی از روش‌های یادگیری تحت نظارت به منظور انجام دسته بندی به کار گرفته شده است. همچنین از شبکه‌های پیچشی عمیق که دسته خاصی از شبکه‌های عصبی هستند به روش انتقال یادگیری بهره گیری شده است.

۲-۱- داده کاوی و یادگیری ماشین

به فرایند کشف اطلاعات ارزشمند از داده‌هایی با حجم و پیچیدگی بالا، داده کاوی اطلاق می‌شود که در اکثر زمینه‌ها نظری کسب و کار و تجارت، علوم مهندسی، آماری و سایر شاخه‌های علم به عنوان یک ضرورت پذیرفته شده است. در سال‌های اخیر، با توجه به پیشرفت چشمگیر علوم کامپیوترا و افزایش توان پردازشی کامپیوترا، پیشرفت فناوری ذخیره‌سازی اطلاعات و افزایش نیاز بشر به استخراج اطلاعات بیشتر از بین داده‌ها، توجه ویژه‌ای به دانش داده کاوی در زمینه‌های مختلف علم شده است[۳۵، ۴۶-۴۴].

به طور کلی پیاده‌سازی دانش داده کاوی با توجه به هدف انجام داده کاوی به دو صورت انجام می‌شود که عبارتند از: ۱) داده کاوی پیش‌گویانه و ۲) داده کاوی توصیفی. در این پژوهش داده کاوی پیش‌گویانه پیاده سازی شده است که در این نوع داده کاوی با بررسی داده‌ها، الگوها و قوانین حاکم بر داده‌ها استخراج شده و یک یا چند مدل از سیستم مورد نظر ایجاد می‌شود که می‌توان از این مدل‌ها برای مقاصد مختلف داده کاوی نظری دسته بندی، پیش‌بینی، تخمین و غیره روی داده‌های جدید استفاده نمود.

به منظور پیاده‌سازی داده کاوی می‌توان از علوم مختلف استفاده نمود که یادگیری ماشین و آمار دو مورد از مهمترین علومی هستند که در داده کاوی کاربرد گستردگی دارند. روش‌های یادگیری ماشین

۱ Supervised

۲ Unsupervised

۳ Semi-Supervised

هستند که در آنالیز داده‌هایی که دارای ساختار شبکه‌ای هستند، کاربرد گسترده‌ای دارند [۴۰، ۵۵]. این دسته از شبکه‌های عصبی قابلیت آنالیز داده‌هایی با یک بعد (مانند متن و صوت)، دو بعد (مانند تصویر) و سه بعد (مانند فیلم) را دارد [۵۶، ۵۴]. در سال‌های اخیر، با توجه به قابلیت‌های این دسته از تکنیک‌های یادگیری عمیق در استخراج خودکار ویژگی‌ها، تشخیص اشیا، دسته بندی تصاویر و ... تحقیقات گسترده‌ای به منظور بهره‌گیری از این تکنیک برای تشخیص و دسته‌بندی خرابی‌های روسازی انجام شده است که برای نمونه می‌توان مراجع [۳۱، ۳۴، ۴۰، ۵۷-۶۵] مطالعه کرد. به طور کلی ساختار شبکه‌های عصبی پیچشی از سه قسمت اصلی تشکیل شده است که عبارتند از لایه‌های پیچشی^۱، لایه‌های ترکیب^۲ و لایه‌های با اتصال کامل^۳.

لایه‌های پیچشی از چند طرح‌واره^۴ تشکیل شده اند که هر یک از طرح‌ها از طریق لغزش و جابه‌جایی یک ناحیه کوچک با ابعاد مشخص روی داده ایجاد می‌شود. این ناحیه کوچک به عنوان ناحیه محلی شناخته می‌شود. عملیات تشکیل لایه‌های پیچشی بر اساس ناحیه محلی تعیین شده می‌تواند برای انواع داده‌ها نظیر کارکترهای یک متن، پیکسل‌های یک تصویر و سایر موارد مشابه به کار گرفته شود. با توجه به نحوه تشکیل لایه‌های پیچشی می‌توان گفت که برخلاف شبکه‌های عصبی معمولی، در شبکه‌های عصبی پیچشی هر نرون در یک لایه به تمامی نرون‌های لایه قبلی متصل نیست بلکه هر نرون فقط به نرون‌های موجود در ناحیه محلی لایه قبل اتصال دارد [۳۱، ۳۶، ۴۰، ۵۵، ۶۱، ۶۶-۶۸]. در شکل ۴ نمایی از نحوه تشکیل لایه‌های پیچشی ارائه شده است.

لایه‌های ترکیب معمولاً بلافصله بعد از لایه‌های پیچشی قرار می‌گیرند. این لایه‌ها با هدف خلاصه‌سازی، ساده سازی و کاهش ابعاد لایه‌های پیچشی در ساختار شبکه قرار می‌گیرند و به ایجاد طرح‌واره‌های متراکم‌تر منجر می‌شوند. عملیات ترکیب به شکل‌های مختلفی قابل انجام می‌باشد که روش‌های مبتنی بر میانگین و انتخاب بیشینه، دو مورد از روش‌های پرکاربرد برای پیاده‌سازی عملیات ترکیب به حساب می‌آیند [۳۱، ۳۶، ۴۰، ۳۶، ۶۱، ۶۶-۶۹]^۵ و در شکل ۵ نحوه ایجاد لایه‌های ترکیب به دو روش ذکر شده نمایش داده شده است.

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 بعد خروجی شبکه است که در یک شبکه با هدف دسته‌بندی تعداد دسته‌ها به عنوان بعد خروجی در نظر گرفته می‌شود.

یادگیری پارامترهای شبکه عمیق با توجه به N داده‌ی آموزشی به صورت یک مسئله بهینه‌سازی مطرح می‌شود. بدین صورت که در یک مسئله با هدف دسته‌بندی، هر ردیف از X یک داده را در \mathbb{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 [۵۲].

$$\begin{aligned} Y \in \mathbb{R}^{N \times C} \quad , \quad X \in \mathbb{R}^{N \times D} \\ \text{Min } \ell(Y, \Phi(X, W^1, W^2, \dots, W^k)) + \\ \lambda \Theta(W^1, W^2, \dots, W^k) \end{aligned} \quad (4)$$

در رابطه فوق، یکتابع زیان^۶ ($\ell(Y, \Phi(X, W^1, W^2, \dots, W^k))$) تفاوت بین کلاس‌های از پیش تعیین شده (\bar{Y}) و کلاس‌های پیش‌بینی شده بر اساس رابطه Θ را مشخص می‌کند. همچنین یکتابع تنظیم^۷ (Θ) برای جلوگیری از اضافه برازش^۸ مدل و λ به عنوان پارامتر تعدیل با مقدار مثبت در نظر گرفته می‌شود. برای اطلاعات بیشتر در مورد ساختار مدل‌های یادگیری عمیق می‌توان به مراجع [۵۲، ۵۳] مراجعه نمود.

یادگیری عمیق به عنوان یکی از تکنیک‌های یادگیری ماشین را می‌توان برای هر سه نوع یادگیری (تحت ناظارت، بدون ناظارت و نیمه ناظارتی) به کار گرفت و کاربرد گسترده‌ای در آنالیز داده‌های عظیم، تشخیص گفتار، تشخیص اجسام، بینایی ماشین، علم رباتیک، خودروهای خودران و ... دارد [۳۲، ۳۷].

۲-۳- شبکه عصبی پیچشی

شبکه‌های عصبی پیچشی نوع خاصی از مدل‌های یادگیری عمیق

⁴ Convolution Layers

⁵ Pooling Layers

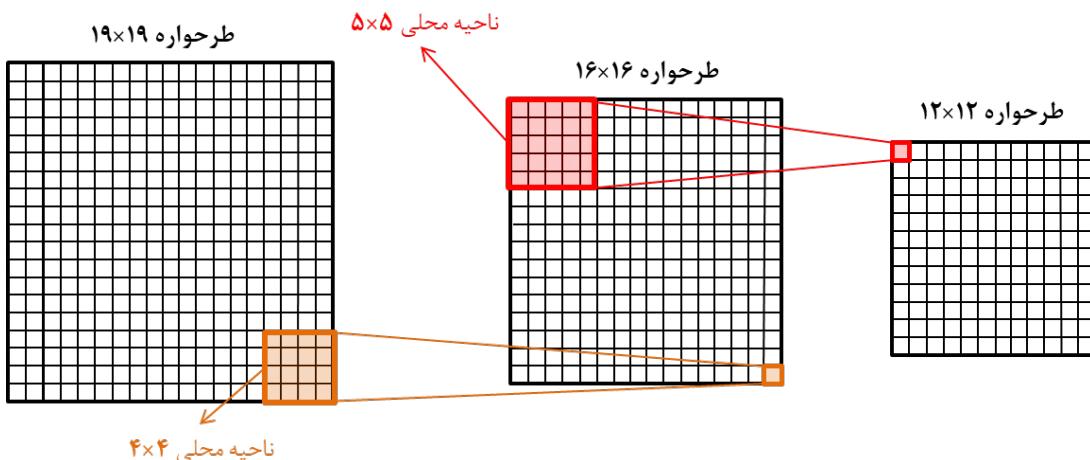
⁶ Fully Connected Layers

⁷ Feature Map

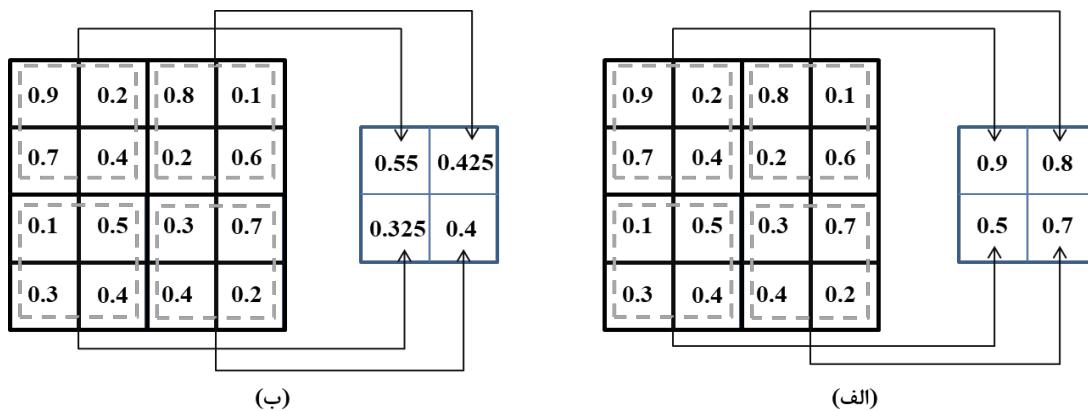
¹ Loss Function

² Regularization Function

³ Overfitting



شکل ۴. فرایند تشکیل لایه‌های پیچشی
Fig. 4. Process of creating convolutional layers



شکل ۵. نحوه ایجاد لایه ترکیب به روش (a): میانگین بیشینه (b): میانگین
Fig. 5. Creating pooling layers using (a) max-pooling, (b) mean

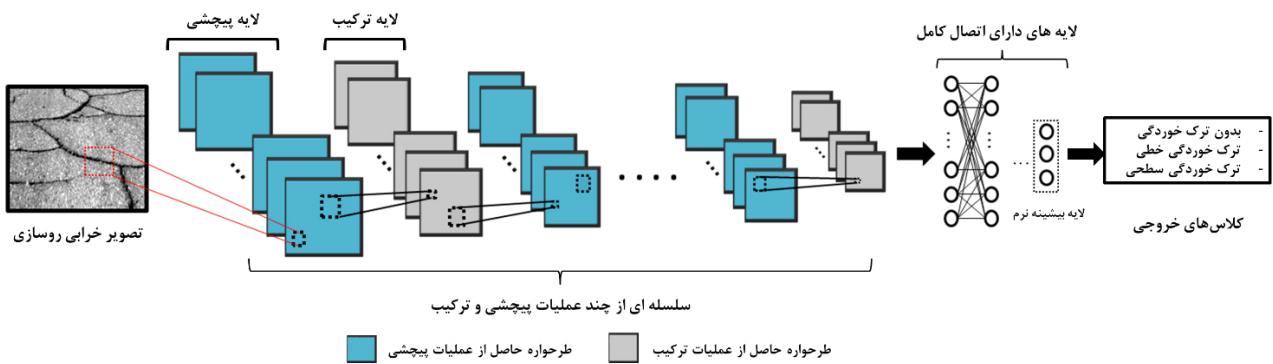
خوردگی خطی و با ترک خوردگی سطحی در شکل ۶ ارائه شده است. در حالت کلی رایج‌ترین روش‌ها به منظور ایجاد شبکه‌های عصبی پیچشی عبارت اند از: ۱) ایجاد شبکه از پایه و انجام تمامی مراحل و الزامات ساخت شبکه و ۲) استفاده از روش انتقال یادگیری با بهره‌گیری از مدل‌های از پیش تعلیم یافته.

در روش اول، برای ایجاد شبکه نیاز است که تمامی اجزا و پارامترهای شبکه توسط افراد متخصص تعیین و طراحی شوند که این امر با توجه به پیچیدگی ساختار شبکه و گستردگی پارامترها نیازمند تخصص بالا و صرف وقت زیاد است. همچنین در این روش به منظور ایجاد شبکه کارامد نیاز به حجم انبوهی از داده وجود دارد که این امر نیز موجب زمان بر شدن روند ساخت شبکه و نیاز به سیستم پردازشی قدرتمند خواهد شد. مولفه‌های مهم و تأثیر گذار بر عملکرد

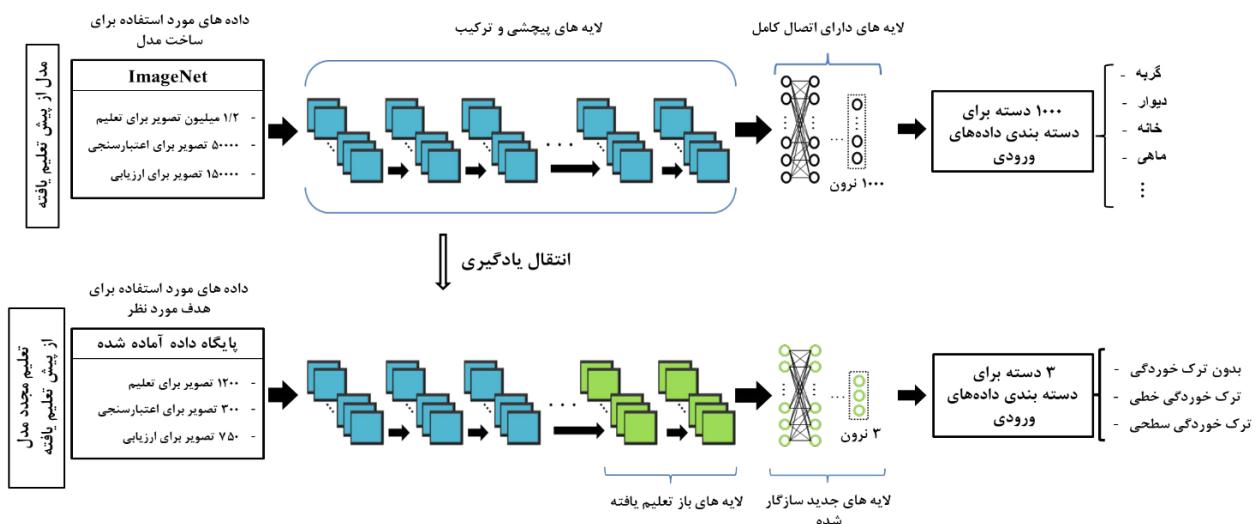
لایه‌های دارای اتصال کامل آخرین لایه‌های قرار گرفته در ساختار شبکه‌های عصبی پیچشی محسوب می‌شوند. این بخش می‌تواند از یک یا چند لایه تشکیل شود. در این لایه‌ها، مهمترین اطلاعات داده‌های ورودی تجمعی می‌شوند و می‌توان از این اطلاعات برای برخی از وظایف نظری پیش‌بینی، دسته‌بندی استفاده نمود. آخرین لایه از لایه‌های دارای اتصال کامل، لایه بیشینه نرم^۱ است که اغلب در مسائل پیش‌بینی و دسته‌بندی کاربرد دارد و وظیفه تعیین احتمال وقوع هریک از کلاس‌ها را بر عهده دارد. [۶۱، ۳۶، ۶۱، ۴۰، ۶۶]

ساختار کلی شبکه عصبی پیچشی به کار گرفته شده در این پژوهش برای استخراج ویژگی‌ها و تشخیص خرابی ترک خوردگی و دسته‌بندی تصاویر روسازی به سه دسته بدون ترک خوردگی، با ترک

¹ Softmax Layer



شکل ۶. ساختار شبکه عصبی پیچشی در این مقاله
Fig. 6. Structure of applied convolutional neural network



شکل ۷. به کارگیری روش انتقال یادگیری
Fig. 7. Using the transfer learning method

زمان کمتر، با تعداد داده‌های کمتر و با صرف توان پردازشی کمتر را فراهم می‌آورد [۳۶، ۵۷، ۷۷-۷۵]. در شکل ۷ نمایی کلی از نحوه به کارگیری روش انتقال یادگیری در این پژوهش ارائه شده است. همانطور که در این شکل مشخص شده است، در این پژوهش از مدل‌های از پیش تعلیم یافته که بر اساس بیش از یک میلیون تصویر و با هدف دسته‌بندی تصاویر در ۱۰۰۰ دسته مختلف ایجاد شده اند برای ساخت مدل‌هایی بر اساس ۱۵۰۰ تصویر و با هدف دسته بندی تصاویر در سه دسته استفاده شده است.

شبکه شامل مولفه‌هایی نظری عمق شبکه (تعداد لایه‌های پیچشی، ترکیب و اتصال کامل)، تعداد فیلترها، تعداد گام‌ها ناحیه محلی در فرایند ساخت لایه‌های پیچشی، مکان، سایز و نوع عملیات ترکیب، تعداد اجزای لایه دارای اتصال کامل و بسیاری از موارد دیگر است که تعیین حالت بهینه برای عملکرد شبکه نیاز به تخصص بالا دارد و معمولاً در یک روند سعی و خطا انجام می‌شود [۵۵، ۷۰]. لازم به ذکر است که اخیراً تعیین این مولفه‌ها به عنوان یک چالش بهینه‌سازی برای محققان مطرح شده است [۵۵، ۷۱-۷۴].

در روش دوم، از قابلیت یادگیری و استخراج ویژگی‌ها اساسی در شبکه‌های از پیش تعلیم یافته برای تعلیم مجدد شبکه بر اساس داده‌های جدید استفاده می‌شود و این امر امکان ساخت مدل در

۲-۴- مدل‌های از پیش تعلیم یافته

به منظور بهره‌گیری از تکنیک انتقال یادگیری، از شبکه‌های از

جدول ۱. مشخصات و اطلاعات مدل‌های از پیش تعلیم یافته
Table 1. More information on pre-trained models

مدل از پیش تعلیم یافته	اندازه تصاویر ورودی	(تعداد لایه‌ها)	عمق شبکه	تعداد پارامترها (میلیون)	اندازه مدل (مگابایت)	تعداد داده مورد استفاده در ساخت شبکه	تعداد دسته‌های خروجی
AlexNet	(۲۲۷×۲۲۷×۳)	۸	۶۱	۲۲۷	۴۶	بیش از یک میلیون تصویر از پایگاه داده ImageNet	۱۰۰۰
SqueezeNet	(۲۲۷×۲۲۷×۳)	۱۸	۱/۲۴	۴۶	۲۷		
GoogleNet	(۲۲۴×۲۲۴×۳)	۲۲	۷	۲۷	۴۴		
ResNet-18	(۲۲۴×۲۲۴×۳)	۱۸	۱۱/۷	۹۶	۲۵/۶		
ResNet-50	(۲۲۴×۲۲۴×۳)	۵۰	۲۵/۶	۱۶۷	۴۴/۶		
ResNet-101	(۲۲۴×۲۲۴×۳)	۱۰۱	۴۴/۶	۸۹	۲۳/۹		
Inception-V3	(۲۹۹×۲۹۹×۳)	۴۸	۲۳/۹	۷۷	۲۰		
DenseNet-201	(۲۲۴×۲۲۴×۳)	۲۰۱	۲۰	۷۷			

شده است. در این روش، توزیع مقادیر پیکسل‌های تصویر گستردگر و شدت مقادیر متعادل‌تر می‌شود و در نتیجه تصاویری با روشنی و پسچش بالاتری را ایجاد می‌کند [۸۶-۸۸، ۱۴]. در شکل ۸ نمونه‌هایی از تاثیر این تکنیک بر وضوح تصاویر ارائه شده است.

۳- انجام مدل‌سازی

در این بخش، روند ساخت مدل‌های دسته‌بندی و تشخیص خرامی ترک خورده‌گی تشریح خواهد شد. روند انجام پژوهش از دو قسمت اصلی تشکیل شده است که شامل آماده‌سازی داده‌های ورودی و تنظیم پارامترهای اصلی و موثر بر فرایند یادگیری است.

۳-۱- آماده‌سازی پایگاه داده

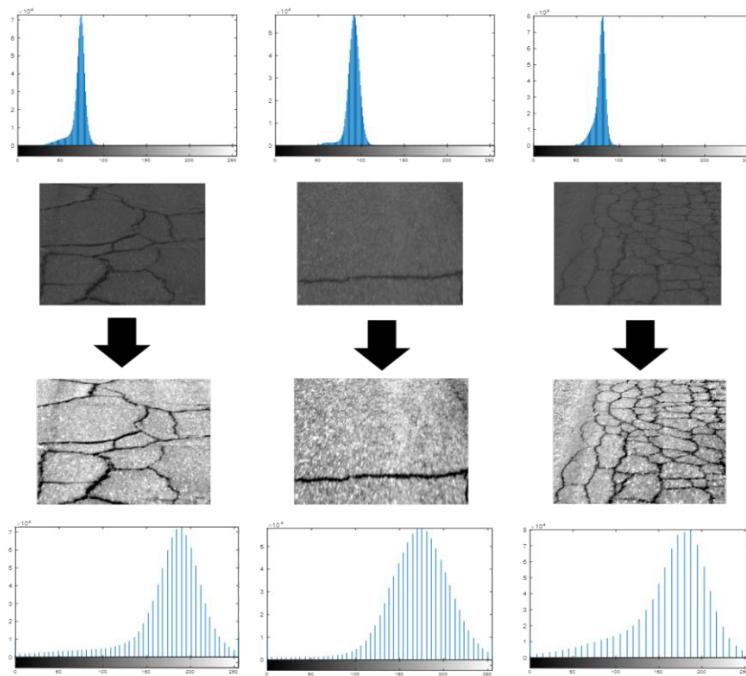
به منظور ساخت مدل‌های تشخیص و دسته‌بندی خرامی ترک خورده‌گی روسازی، در ابتدا باید مجموعه‌ای از داده‌های با کیفیت برای استفاده به عنوان ورودی در فرایند یادگیری ایجاد شود. با توجه به اینکه در اکثر سازمان‌ها برداشت تصاویر روسازی در شرایط نوری مناسب و در روز انجام می‌شود، در این پژوهش با فرض اینکه تصاویر در شرایط مناسب و در روز برداشت شده باشند، پایگاه داده‌ای متشکل از سه دسته از تصاویر روسازی ساخته شده است که شامل تصاویر بدون ترک خورده‌گی، تصاویر دارای ترک خطی و تصاویر دارای ترک سطحی می‌شود. لازم به ذکر است که هرچه تنوع و تعداد تصاویر در هر دسته بیشتر باشد، احتمال بروز مشکل اضافه برآش ۲ کاهش

پیش تعلیم یافته برای ساخت شبکه مورد نظر استفاده می‌شود. این شبکه‌ها توسط متخصصین بر اساس مناسب ترین پارامترها و بهترین ساختار شبکه روی تعداد بسیار زیاد داده (۱/۲ میلیون تصویر) برای دسته‌بندی تصاویر در ۱۰۰۰ دسته ایجاد شده‌اند. در این پژوهش عملکرد مدل‌های ایجاد شده به روش انتقال یادگیری بر اساس هشت شبکه از پیش تعلیم یافته برای تشخیص و دسته‌بندی ترک‌های روسازی مورد ارزیابی قرار داده شده است. هشت مدل از پیش تعلیم یافته عبارت اند از ResNet-18، ResNet-50، ResNet-101 و DenseNet-201. در جدول ۱ مشخصات و اطلاعات تکمیلی مربوط به شبکه‌های از پیش تعلیم یافته که در این مقاله مورد بررسی قرار گرفته‌اند ارائه شده است.

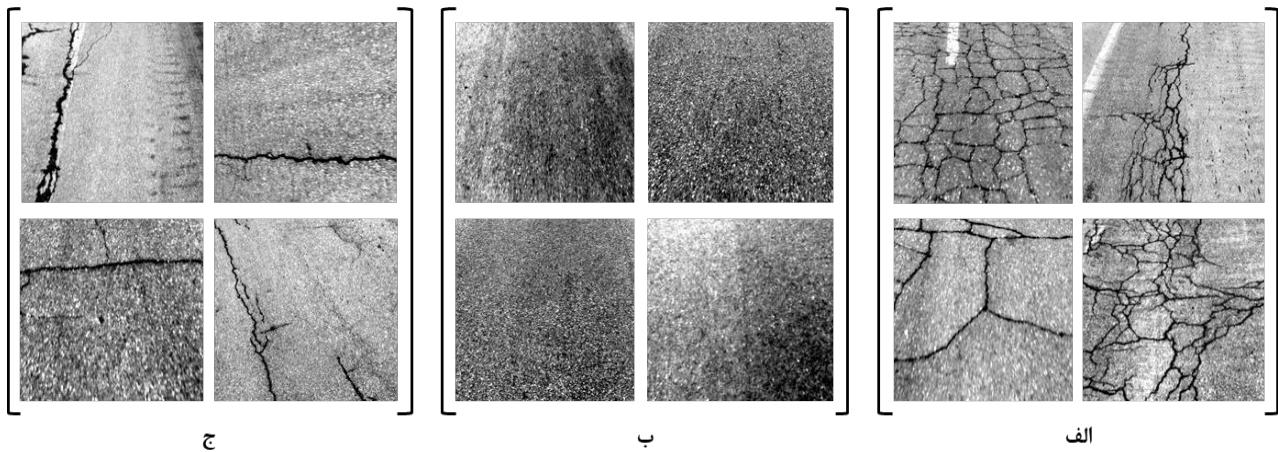
همان‌طور که در جدول ۱ مشاهده می‌شود، با توجه به اختلاف زیاد در ویژگی‌هایی نظیر عمق شبکه و تعداد پارامترها می‌توان انتظار داشت که مدل‌ها عملکرد متفاوتی از نظر سرعت و دقیقت ارائه دهند.

۴- پیش‌پردازش تصاویر

به طور معمول تصاویر برداشت شده از سطح روسازی کیفیت لازم برای استفاده به عنوان ورودی فرایند ساخت مدل‌های دسته‌بندی را ندارند. بر همین اساس قبل از ورود تصاویر به فرایند ساخت مدل از روش تعديل هیستوگرام^۱ به منظور افزایش وضوح تصاویر، استفاده



شکل ۸. تأثیر روش متعادل‌سازی هیستوگرام بر وضوح و کیفیت تصاویر
Fig. 8. Effect of histogram equalization on clarity and quality of images



شکل ۹. نمونه داده‌های به کار گرفته شده؛ الف: تصاویر دارای ترک سطحی، ب: تصاویر بدن ترک، ج: تصاویر دارای ترک خطی
Fig. 9. Samples of image datasets: (a) surface cracking, (b) no-cracking, (c) linear cracking

عملیات یادگیری فراهم شود. با توجه به محدودیت‌های توان پردازش، برای این هدف در هر یک از دسته‌های پایگاه داده ۵۰۰ تصویر با ابعاد 1000×900 در مقیاس خاکستری^۱ برای تعلیم مدل‌ها جمع‌آوری شده است که با توجه به حجم داده‌ها از این مقدار 80 درصد برای عملیات یادگیری و مابقی برای عملیات اعتبارسنجی^۲ در نظر گرفته

می‌باید ولی از سوی دیگر زمان تعلیم مدل‌ها افزایش می‌یابد و توان پردازشی بیشتری را می‌طلبد.

در دانش داده‌کاوی کیفیت مناسب داده‌ها تأثیر بسیار عمیقی بر نتایج بدست آمده دارد. بر همین اساس در روند داده‌کاوی عموماً 80 درصد زمان پژوهش صرف فراهم کردن داده‌های مناسب خواهد شد و مابقی زمان به مدل‌سازی و ارزیابی اختصاص می‌یابد. در این مقاله تلاش شده است که داده‌هایی با کیفیت و تنوع کافی برای شروع

¹ Gray Scale Validation

جدول ۲. داده‌های جمع‌آوری شده
Table 2. Collected datasets

عملیات ارزیابی	عملیات یادگیری		دسته بندی
	اعتبارسنجی	تعلیم	
۲۵۰	۱۰۰	۴۰۰	بدون ترک خوردگی
۲۵۰	۱۰۰	۴۰۰	ترک خوردگی خطی
۲۵۰	۱۰۰	۴۰۰	ترک خوردگی سطحی
۷۵۰	۱۵۰۰		مجموع

خواهد شد. در این پژوهش همانطور که در شکل ۱۰ نمایش داده شده است، با بررسی روند تعلیم مدل‌ها می‌توان گفت که نرخ خطأ 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 نمونه‌ها (داده‌ها) در هر تکرار است. تعداد نمونه‌ها در هر تکرار می‌تواند بین یک تا تعداد داده‌های تعلیم انتخاب شود. تعداد زیاد نمونه‌ها 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 داده‌های 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 مشکل‌کل از ۱۲۰۰ نمونه (داده) نیاز است و در مجموع برای انجام ۱۵ دوره یادگیری، ۱۲۰۰ 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

شده است. همچنین برای هریک از دسته‌ها ۲۵۰ تصویر متفاوت از تصاویر تعلیم، برای ارزیابی مدل در نظر گرفته شده است. در شکل ۹ چند نمونه از تصاویر به کار گرفته شده در این پژوهش به منظور ساخت مدل‌ها نمایش داده شده است.

همانطور که در جدول ۲ مشاهده می‌شود، در مجموع ۱۵۰۰ تصویر در روند یادگیری مدل‌ها استفاده شده است که از این تعداد ۱۲۰۰ تصویر برای تعلیم و ۳۰۰ تصویر برای اعتبارسنجی به کار گرفته شده است. همچنین در مجموع ۷۵۰ تصویر برای ارزیابی مدل‌ها جمع‌آوری و استفاده شده است.

۳-۲- پارامترهای اساسی فرایند یادگیری
پیش از آغاز فرایند ساخت مدل‌ها، باید برخی از پارامترهای موثر در روند یادگیری تعیین شوند که از آن جمله می‌توان به تعداد دوره‌ها^۱، تعداد داده در تکرار^۲، تعداد تکرار^۳، نرخ یادگیری^۴ و مقدار تکانه^۵ اشاره نمود. در این بخش توضیحاتی پیرامون تنظیم این پارامترها ارائه شده است.

تعداد دوره‌های یادگیری به تعداد دفعاتی که تمامی داده‌های تعلیم در روند یادگیری مدل‌ها به کار گرفته می‌شوند، اطلاق می‌شود. در صورتی که تعداد دوره‌ها زیاد در نظر گرفته شوند، سبب بروز مشکلاتی نظیر اضافه برازش و افزایش زمان پردازش می‌شود. از سوی دیگر، کم بودن تعداد دوره‌ها سبب ناقص انجام شدن فرایند یادگیری

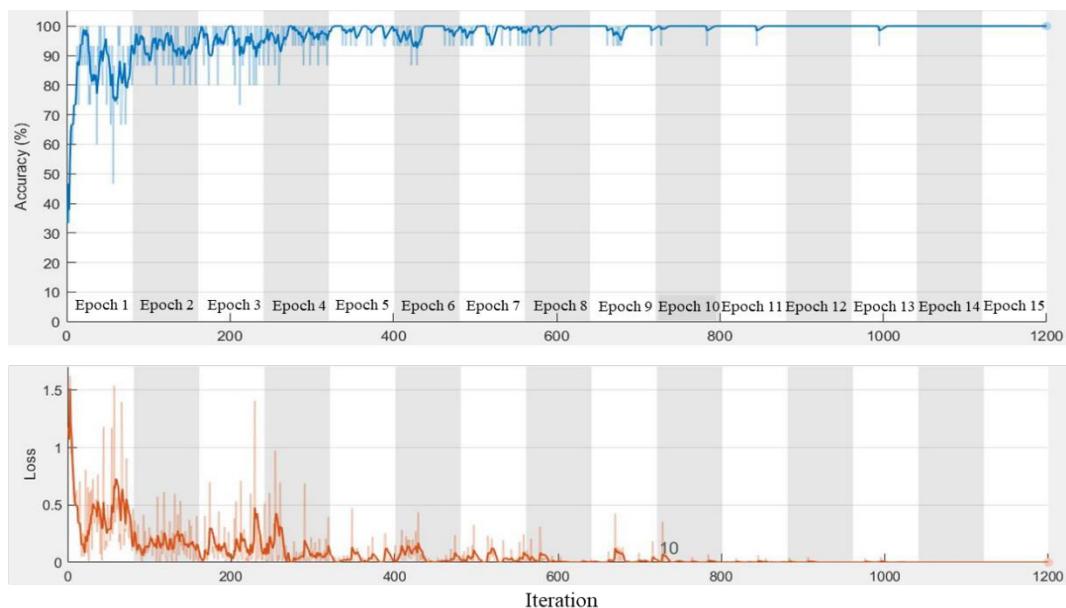
1 Epoch

2 Batch Size

3 Iterations

4 Learning Rate

5 Momentum



شکل ۱۰. نمونه ای از روند تعلیم مدلها
Fig. 10. Sample of the training process

جدول ۳. زمان طی شده در مراحل مختلف(ثانیه)
Table 3. The Spent time in various stages (second)

مدل	زمان پیش پردازش (برای هر تصویر)	زمان تعلیم مدل ها (برای هر تصویر)	زمان ارزیابی مدل ها (برای هر تصویر)
AlexNet	۰/۴۸۲	۰/۰۱۹	
SqueezeNet	۰/۳۸۳	۰/۰۱۷	
GoogleNet	۰/۶۳۷	۰/۰۲۴	
ResNet-18	۰/۶۴۴	۰/۰۲۱	
ResNet-50	۱/۹۴۴	۰/۰۴۱	۰/۰۵۸
ResNet-101	۲/۸۲۳	۰/۰۵۴	
DensaNet-201	۱۲/۹۰۸	۰/۰۸۹	
Inception-V3	۲/۹۵۱	۰/۰۵۳	

سرعت مدلها در یادگیری و اجرا و دقت مدلها در تشخیص و دسته بندی ترکها به عنوان دو پارامتر اصلی عملکرد مدلها در ادامه آرائه شده است.

۴-۱- سرعت یادگیری و دسته بندی داده های جدید

همانطور که در جدول ۳ 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

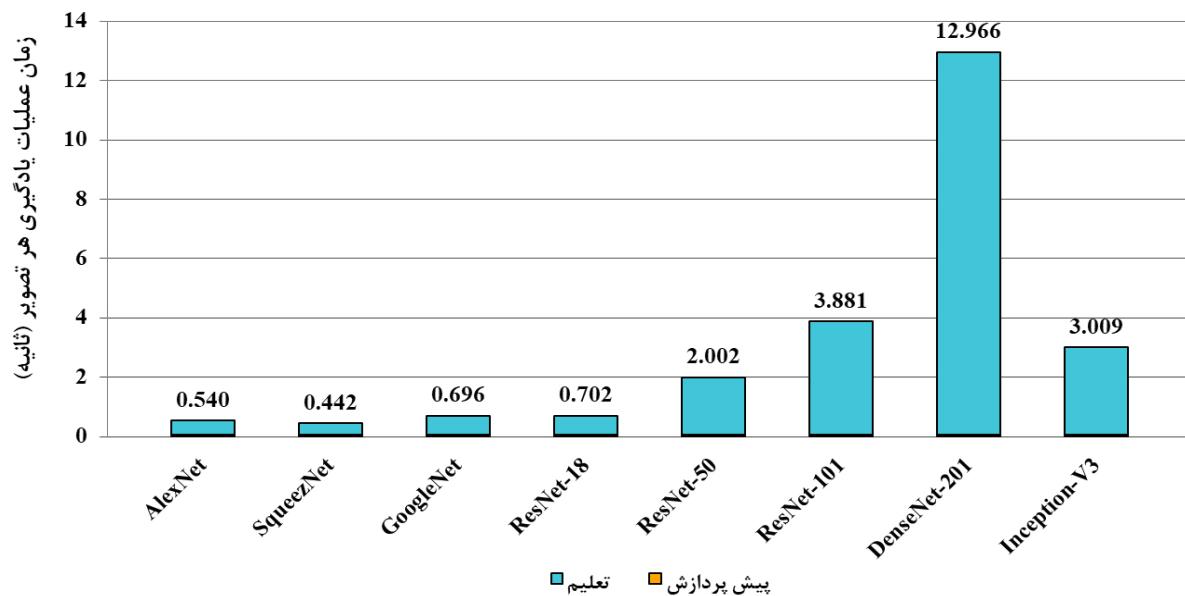
یادگیری تأثیر داشته و اغلب در مطالعات مختلف به ترتیب ۱۰۰۰ و ۹۰۰ در نظر گرفته می شوند.

در این مقاله، پارامترهای تأثیرگذار بر عملیات یادگیری در تمامی مدل های 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 (طبقاً جدول ۱) منجر به عدم کفایت فضای حافظه برای انجام عملیات یادگیری می شود. به همین دلیل تعداد نمونه در هر تکرار مدل ResNet-101 برابر ۱۲ در نظر گرفته شده است.

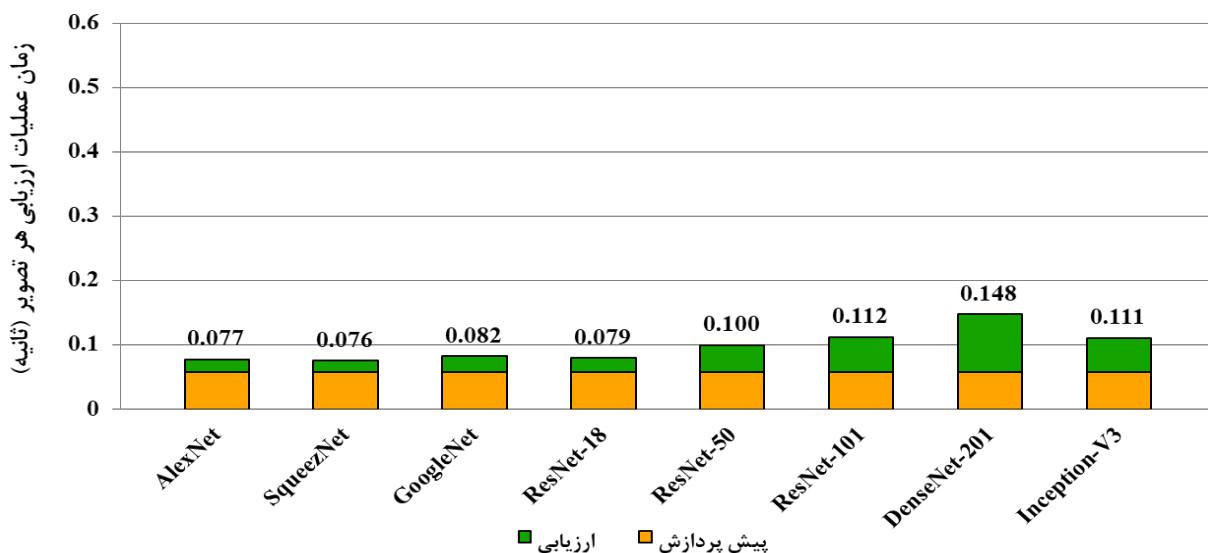
تمامی پردازش ها و محاسبات انجام شده در این مقاله با استفاده از یک کامپیوتر شخصی با سیستم اجرایی ۶۴ بیتی، ۸ گیگابایت فضای حافظه، پردازنده Intel(R) Core i7-4710HQ @ 2.50 GHz و پردازنده گرافیکی GeForce GTX 850M انجام شده اند. همچنین عملیات پردازش تصویر و پیاده سازی یادگیری عمیق در نرم افزار MATLAB 2018b اجرا شده است.

۴- نتایج

پس از انجام فرایند یادگیری مدلها بر اساس داده های تعلیم و ارزیابی دقت بر اساس داده های آزمون، نتایج به دست آمده از ارزیابی



شکل ۱۱. مقایسه سرعت مدلها در عملیات یادگیری
Fig. 11. Speed of models in the training process



شکل ۱۲. مقایسه سرعت مدل‌ها در عملیات ارزیابی
Fig. 12. Speed of models in the testing process

GoogleNet، AlexNet، AlexNet خود اختصاص داده است. مدل‌های ResNet-18، SqueezeNet، SqueezeNet با انجام فرایند یادگیری در کمتر از یک ثانیه و انجام عملیات ارزیابی تصاویر جدید در کمتر از ۰/۱ ثانیه، سرعت بالاتری نسبت به سایر مدل‌ها در عملیات یادگیری و ارزیابی داشته‌اند.

در بین مدل‌های ارزیابی شده، مدل SqueezeNet با صرف زمان ۰/۴۴۲ ثانیه برای هر تصویر در عملیات یادگیری و

ارزیابی مدل‌ها انجام می‌شود، در شکل‌های ۱۱ و ۱۲ مقایسه سرعت عملکرد مدل‌ها در عملیات یادگیری (پیش پردازش و تعلیم) و عملیات ارزیابی (پیش پردازش و ارزیابی) ارائه شده است. همانطور که در این شکل‌ها مشاهده می‌شود در عملیات یادگیری بخش ناچیزی از زمان عملیات به پیش پردازش داده‌ها اختصاص یافته است. از سوی دیگر فرایند پیش‌پردازش تصاویر در عملیات ارزیابی عملکرد مدل‌ها، بخش قابل توجهی از زمان را به

جدول ۴. ارزیابی جامع عملکرد مدلها
Table 4. Performance of models

مدل	دسته	Accuracy	Sensitivity	Specificity	Precision	F-score
AlexNet	ترک خطی	0.968	0.951	0.977	0.953	0.952
	بدون ترک	0.996	0.999	0.995	0.991	0.995
	ترک سطحی	0.969	0.951	0.978	0.957	0.953
	کل	0.978	0.967	0.983	0.967	0.967
SqueezeNet	ترک خطی	0.986	0.989	0.985	0.970	0.980
	بدون ترک	0.999	0.999	0.999	0.997	0.998
	ترک سطحی	0.987	0.969	0.995	0.991	0.980
	کل	0.991	0.986	0.993	0.986	0.986
GoogleNet	ترک خطی	0.984	0.980	0.985	0.971	0.975
	بدون ترک	0.999	0.997	1.000	1.000	0.999
	ترک سطحی	0.984	0.973	0.990	0.980	0.977
	کل	0.989	0.984	0.992	0.984	0.984
ResNet-18	ترک خطی	0.968	0.964	0.971	0.943	0.953
	بدون ترک	0.997	0.999	0.996	0.992	0.995
	ترک سطحی	0.972	0.943	0.986	0.971	0.957
	کل	0.979	0.968	0.984	0.969	0.968
ResNet-50	ترک خطی	0.961	0.932	0.976	0.951	0.941
	بدون ترک	0.996	1.000	0.994	0.988	0.994
	ترک سطحی	0.965	0.952	0.972	0.944	0.948
	کل	0.974	0.961	0.981	0.961	0.961
ResNet-101	ترک خطی	0.957	0.948	0.962	0.926	0.937
	بدون ترک	0.996	0.988	1.000	1.000	0.994
	ترک سطحی	0.961	0.936	0.974	0.947	0.942
	کل	0.972	0.957	0.979	0.958	0.957
DenseNet-202	ترک خطی	0.976	0.964	0.982	0.964	0.964
	بدون ترک	1.000	1.000	1.000	1.000	1.000
	ترک سطحی	0.976	0.964	0.982	0.964	0.964
	کل	0.984	0.976	0.988	0.976	0.976
Inception-V3	ترک خطی	0.977	0.972	0.980	0.960	0.966
	بدون ترک	1.000	1.000	1.000	1.000	1.000
	ترک سطحی	0.977	0.960	0.986	0.972	0.966
	کل	0.985	0.977	0.989	0.977	0.977

۴-۲- دقت مدل‌ها

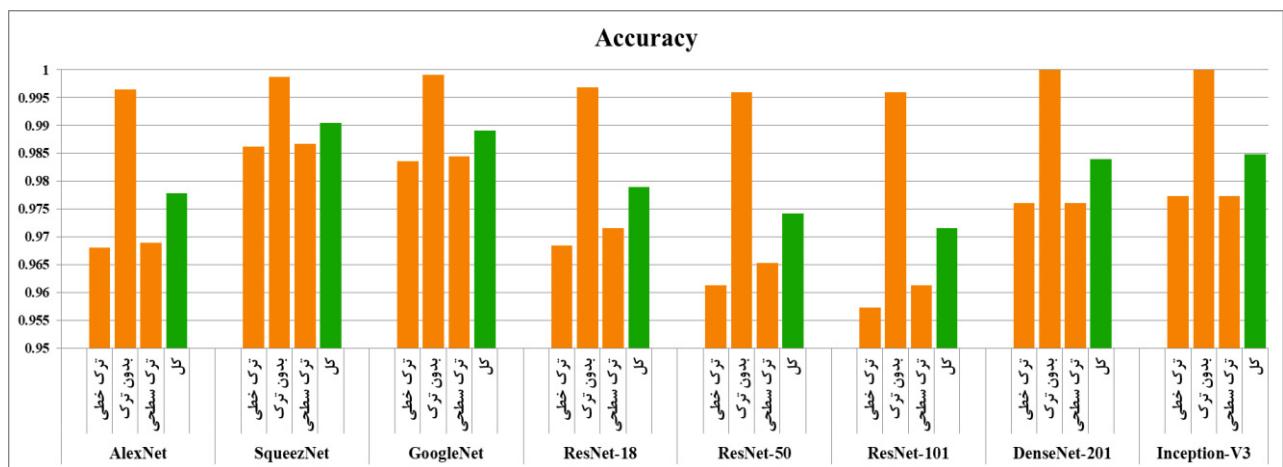
تشکیل ماتریس درهم ریختگی^۱ یکی از بهترین روش‌های ارزیابی

ثانیه به ازای هر تصویر در عملیات ارزیابی، سریع‌ترین عملکرد و مدل

DenseNet-201 با صرف زمان ۱۲/۹۶۶ و ۱۴۸ ثانیه به ترتیب

برای یادگیری و ارزیابی، کندرین عملکرد را داشته است.

1 Confusion Matrix



شکل ۱۳. ارزیابی عملکرد مدلها بر اساس معیار Accuracy
Fig. 13. Performance of models based on the accuracy index

دقت مدل‌های ایجاد شده برای انجام پیش‌بینی و دسته‌بندی به ویژه

در مسائلی با بیش از دو دسته است [۱۸]. این ماتریس با مقایسه‌ی نتایج حاصل از مدل با واقعیت، پاسخ‌های به دست آمده از مدل‌ها در هر یک از دسته‌ها را با چهار حالت ممکن پاسخ مثبت صحیح (TP^۱)، پاسخ منفی صحیح (TN^۲)، پاسخ مثبت غلط (FP^۳) و پاسخ منفی غلط (FN^۴) بررسی می‌کند.

پس از تعیین اجزای ماتریس درهم ریختگی می‌توان کارایی و عملکرد مدل‌ها در دسته‌بندی و تشخیص صحیح ترک‌ها را با استفاده از چند معیار اساسی ارزیابی نمود. sensitivity، accuracy، specificity و F-score از جمله پرکاربردترین معیارها در ارزیابی عملکرد و دقت مدل‌ها در مسائل دسته‌بندی و پیش‌بینی هستند. در جدول ۴ مقادیر این معیارها برای هر یک از مدل‌ها ارائه شده است و این بخش از مقاله به مقایسه عملکرد مدل‌ها بر اساس معیارهای ذکر شده می‌پردازد.

۴-۲-۱- معیار Accuracy

این معیار یکی از رایج‌ترین معیارهای ارزیابی مدل‌ها به شمار می‌رود و بر اساس رابطه ۶ یک نمای کلی از میزان دقت مدل‌ها با تعیین نسبت پاسخ‌های صحیح (TP و TN) به کل پاسخ‌ها ارائه

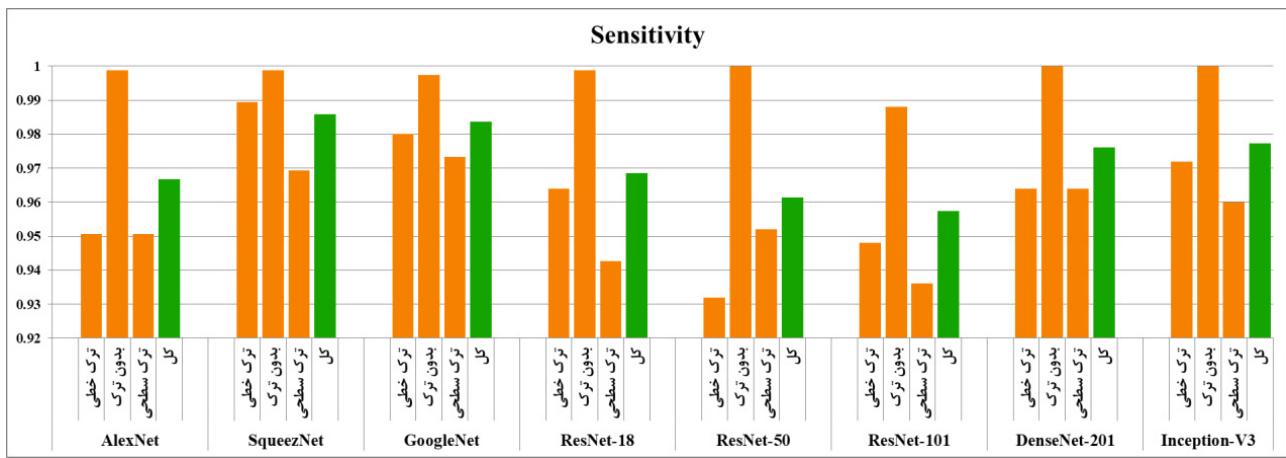
$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (6)$$

ارزیابی دقیق و مقایسه عملکرد مدل‌ها برای دسته‌بندی تصاویر در دسته‌های تعریف شده و همچنین عملکرد کلی مدل‌ها بر اساس معیار accuracy در شکل ۱۳ ارائه شده است. همانطور که در این شکل مشاهده می‌شود، بر اساس این معیار تمامی مدل‌ها بهترین عملکرد را دسته‌بندی و تشخیص تصاویر بدون ترک خوردگی دارند و پس از آن بیشترین پاسخ صحیح در تشخیص خرابی ترک خوردگی سطحی ارائه شده است. همچنین بر اساس این معیار، مدل‌های SqueezeNet و GoogleNet عملکرد بهتری نسبت به سایر مدل‌ها در تشخیص و دسته‌بندی تصاویر دارای ترک خوردگی سطحی و خطی دارند. به طور کلی تمامی مدل‌ها عملکرد مناسبی ارائه داده اند و عملکرد کلی مدل‌ها بر اساس این معیار در محدوده ۰/۹۷۲ تا ۰/۹۹۱ قرار دارد که بهترین عملکرد مربوط به مدل SqueezeNet است و ضعیف‌ترین عملکرد را مدل ResNet-101 دارد.

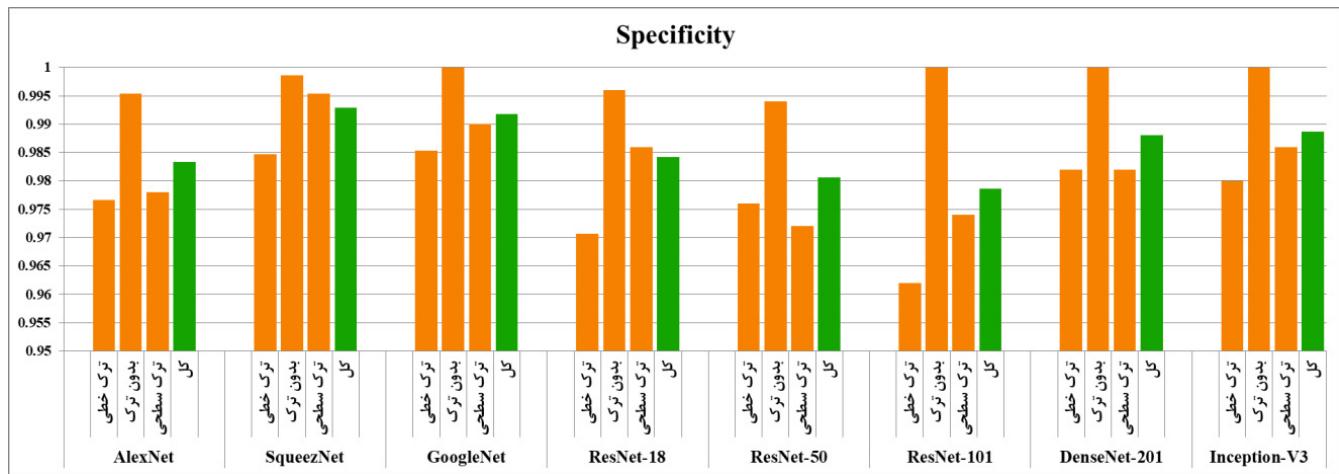
۴-۲-۲- معیار Sensitivity

این معیار میزان توانایی و حساسیت مدل‌ها را در انجام دسته‌بندی صحیح مشخص می‌کند. مطابق رابطه ۷ این امر با محاسبه نسبت پاسخ‌های مثبت صحیح به مجموع پاسخ‌های مثبت صحیح و پاسخ‌های منفی غلط انجام می‌شود. این معیار همچنین با نام‌های نرخ

- 1 True Positive
- 2 True Negative
- 3 False Positive
- 4 False Negative



شکل ۱۴. ارزیابی عملکرد مدلها بر اساس معیار Sensitivity
Fig. 14. Performance of models based on the sensitivity index



شکل ۱۵. ارزیابی عملکرد مدلها بر اساس معیار Specificity
Fig. 15. Performance of models based on the specificity index

و در موقع وقوع ترک خوردگی، عملکرد اغلب مدل ها (به غیر از ResNet-50) در تشخیص ترک خوردگی خطی بهتر از ترک خوردگی سطحی است.

ارزیابی متوسط حساسیت مدل ها در تمامی دسته ها و قرارگیری مقادیر در محدوده ۰/۹۸۶ تا ۰/۹۸۷، بیانگر عملکرد خوب مدل های ایجاد شده با تکنیک یادگیری عمیق است و مدل SqueezeNet با حساسیت ۰/۹۸۶ بهترین عملکرد را دارد و به عبارت دیگر در موقعی که باید جواب مثبت بدهد به طور متوسط در ۹۸/۶ درصد موارد به درستی عمل کرده است. همچنین مدل GoogleNet با متوسط حساسیت ۰/۹۸۴ در جایگاه بعدی قرار دارد و در تشخیص تصاویر ترک خوردگی سطحی عملکرد بهتری نسبت به مدل SqueezeNet دارد.

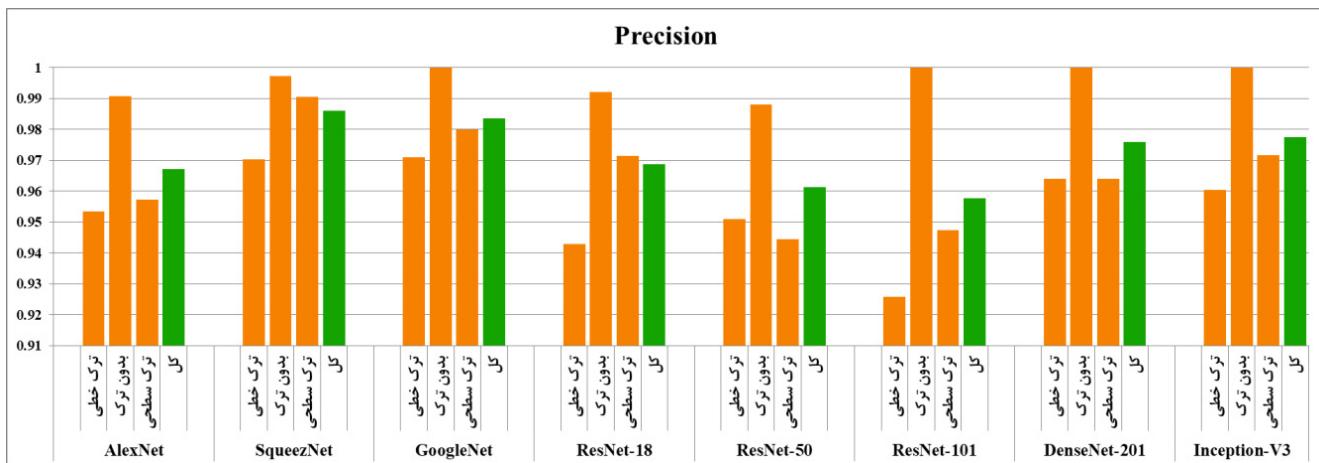
پاسخ مثبت صحیح^۱ و میزان صحت^۲ مدل نیز شناخته می شود.

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

به عبارت دیگر معیار Sensitivity، حساسیت و صحت عملکرد مدل ها در موقعی که باید پاسخ مثبت داشته باشد را ارزیابی می کند. مقایسه حساسیت مدل ها در دسته بندی صحیح تصاویر در شکل ۱۴ 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 بدون ترک خوردگی دارند

¹ True Positive Rate

² Recall



شکل ۱۶. ارزیابی عملکرد مدلها بر اساس معیار Precision
Fig. 16. Performance of models based on the precision index

Precision - ۴-۲-۴

این معیار یکی از پارامترهای مهم در ارزیابی مدل‌ها است که میزان دقت و اعتماد پذیری پاسخ‌های مثبت مدل‌ها را مشخص می‌کند یا به عبارت دیگر احتمال صحیح بودن پاسخ‌های مثبت مدل‌ها را تعیین می‌کند. این معیار با نام ارزش پیش‌بینی مثبت^۳ نیز شناخته می‌شود و مطابق رابطه ۹ محاسبه می‌شود.

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

مطابق جدول ۴ عملکرد کلی مدل‌ها با بررسی متوسط این معیار در تمامی دسته‌ها در محدوده ۰/۹۵۸ تا ۰/۹۸۶ قرار دارد که بیانگر عملکرد مناسب مدل‌ها است. به عبارت دیگر با توجه به ارزیابی این معیار می‌توان با سطح اعتماد بالایی به پاسخ‌های مثبت مدل‌ها ایجاد شده اعتماد کرد. همانطور که در شکل ۱۶ مشاهده می‌شود، پاسخ مثبت مدل‌ها در تشخیص و دسته‌بندی تصاویر بدون ترک دارای بیشترین ارزش (سطح اعتماد) در تمام مدل‌ها است و پس از آن، پاسخ‌های مثبت مدل‌ها (به غیر از 50-ResNet) در دسته ترک سطحی ارزش بالاتری نسبت به دسته ترک خطی دارد. همچنین با توجه به این معیار پاسخ‌های مثبت مدل SqueezeNet با متوسط ۰/۹۸۶ دارای بالاترین ارزش در بین مدل‌ها است.

Specificity - ۴-۲-۳

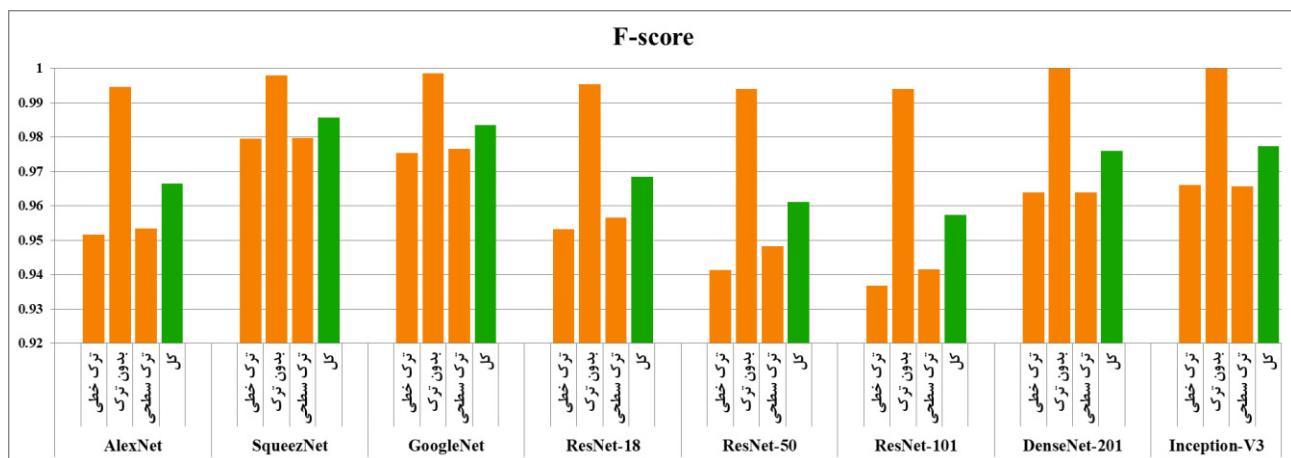
مطابق رابطه ۸، این معیار میزان توانایی مدل‌ها در ایجاد تمایز بین دسته‌ها را با تعیین نسبت پاسخ‌های منفی صحیح به مجموع پاسخ‌های مثبت غلط و پاسخ‌های منفی صحیح مشخص می‌کند. این معیار مفهومی مشابه sensitivity را برای پاسخ‌های منفی ارائه می‌کند و با نام نرخ پاسخ‌های منفی صحیح^۱ نیز شناخته می‌شود.

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

در شکل ۱۵ عملکرد مدل‌ها در موقعی که باید پاسخ منفی بدھند، مقایسه و ارزیابی شده است و همانطور که مشاهده می‌شود در این معیار نیز مشابه سایر معیارها بهترین عملکرد مدل‌ها در دسته بندی تصاویر بدون ترک است و اغلب مدل‌ها (به غیر از ResNet-50) در ارائه پاسخ منفی صحیح برای تصاویر ترک خوردنگی سطحی عملکرد بهتری نسبت به ترک خوردنگی خطی دارند. با ارزیابی متوسط این معیار در همه دسته‌ها برای هر مدل مشخص می‌شود که مدل‌های GoogleNet و SqueezeNet و به ترتیب با متوسط ۰/۹۹۳ و ۰/۹۹۲ عملکرد بهتری نسبت به سایر مدل‌ها دارند. همچنین قرارگیری مقادیر این معیار در محدوده ۰/۹۷۹ تا ۰/۹۹۳ هم مقایسه آن با معیار Sensitivity می‌تواند بیانگر عملکرد بهتر مدل‌ها در ارائه پاسخ منفی نسبت به پاسخ مثبت باشد.

۲ Positive Predictive Value

۱ True Negative Rate



شکل ۱۷. ارزیابی عملکرد مدلها بر اساس معیار F-score
Fig. 17. Performance of models based on the F-score index

۵- جمع‌بندی

جاده‌ها به عنوان بخش اصلی زیرساخت‌های حمل و نقل جاده‌ای، نقش بسیار پر رنگی در رفع نیازهای بشر به جایه‌جایی و ارسال کالا ایفا می‌کند و توسعه کشورها تا حد زیادی به توسعه و مدیریت مناسب شبکه جاده‌ای گره خورده است. از سوی دیگر کیفیت و سلامت جاده‌ها تاثیر مستقیم بر ایمنی و راحتی این شیوه حمل و نقلی دارد و روسازی راه‌ها به عنوان بخش اصلی زیرساخت‌های جاده‌ای تاثیر زیادی بر کیفیت، راحتی و ایمنی حمل و نقل جاده‌ای دارد.

سالانه وقت و هزینه هنگفتی به منظور توسعه و تعمیر و نگهداری شبکه روسازی صرف می‌شود و تحقیقات زیادی برای بهبود عملکرد سامانه مدیریت روسازی انجام شده است که برداشت اطلاعات روسازی یکی از بخش‌های مهم این سامانه است و با توجه رشد روزافزون فناوری‌های مختلف، تلاش‌های گسترشده‌ای به منظور پیاده‌سازی سامانه‌های خودکار برای برداشت دقیق اطلاعات روسازی انجام شده است.

دانش داده کاوی و یادگیری ماشین در سال‌های اخیر به علت پژوهش علوم کامپیوتری و افزایش توان سامانه‌های ذخیره سازی داده به طور چشمگیری در علوم مختلف نظریه مهندسی، پزشکی، علوم مرتبط با تجارت و ... مورد توجه قرار گرفته است. همچنین در سال‌های اخیر پژوهش‌های متعددی به منظور بهره‌گیری از این علوم در مدیریت روسازی انجام شده است که بخش قابل

۴-۲-۵- معیار F-score

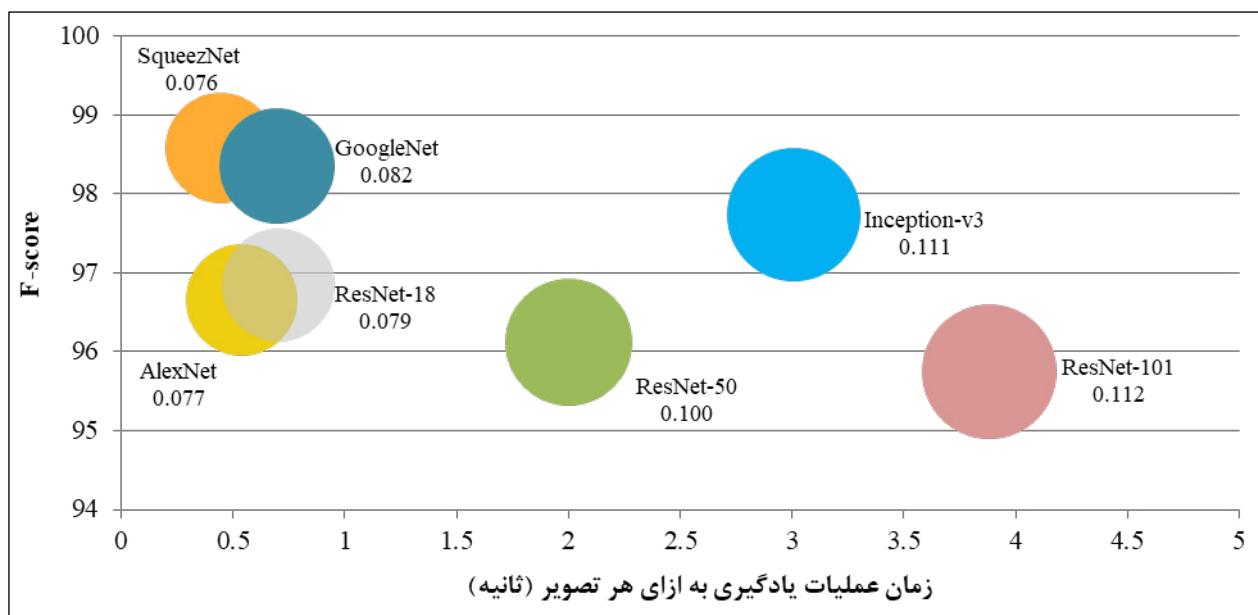
یکی از جامع‌ترین معیارهای ارزیابی دقت و عملکرد مدل‌های دسته‌بندی و پیش‌بینی، معیار F-score است که مطابق رابطه ۱۰ با محاسبه میانگین همساز وزنی^۱ دو معیار Precision و Sensitivity تعیین می‌شود.

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

با توجه به شکل ۱۷، بر اساس این معیار که یک دید جامع از عملکرد مدل‌ها ارائه می‌دهد، عملکرد اغلب مدل‌ها در تشخیص و دسته‌بندی تصاویر ترک خوردگی خطی و سطحی یکسان است و بهترین عملکرد مدل‌ها در دسته‌بندی تصاویر بدون ترک است. همچنین متوسط عملکرد مدل‌ها برای دسته‌های مختلف در محدوده ۰/۹۵۷ تا ۰/۹۸۶ قرار گرفته است که بیانگر توانایی بالای مدل‌های ایجاد شده با تکنیک یادگیری عمیق در تشخیص خرابی ترک خوردگی روسازی است.

بر اساس این معیار مشابه سایر معیارهای مدل‌های مدل‌های GoogleNet و SqueezeNet به ترتیب با متوسط ۰/۹۸۶ و ۰/۹۸۴ عملیات تشخیص و دسته‌بندی خرابی ترک خوردگی را با دقت بالاتری نسبت به سایر مدل‌ها انجام داده‌اند.

¹ Weighted Harmonic Mean



شکل ۱۸. ارزیابی و مقایسه جامع عملکرد مدلها
Fig. 18. A comprehensive comparison of models' performance

هر تصویر در عملیات یادگیری و ۰/۰۷۶ ثانیه بر تصویر در عملیات ارزیابی و همچنین متوسط ۹۸/۶ درصد در معیار F-score بهترین عملکرد را در بین مدل‌ها داشته است. همچنین لازم به ذکر است که در شکل ۱۸ مدل DenseNet-201 به علت عملکرد ضعیف در سرعت یادگیری (۱۲/۹۶۶ ثانیه به ازای هر تصویر) مورد ارزیابی قرار نگرفته است.

نتایج و خروجی این پژوهش را می‌توان در چند نکته مهم جمع‌بندی نمود که عبارت اند از:

- به کارگیری روش‌های مبتنی بر دانش داده کاوی و یادگیری ماشین در زمینه تشخیص و دسته‌بندی خرابی‌های روسازی نظری ترک خورده‌گی، نتایج بسیار خوبی داشته و علیرغم هزینه اجرایی کم، دقت قابل توجهی ارائه کرده است.

- تکنیک یادگیری عمیق به عنوان یکی از مهمترین تکنیک‌های یادگیری ماشین نتایج قابل توجهی در به کارگیری هوش مصنوعی برای تشخیص خرابی ترک خورده‌گی روسازی دارد.

- روش بازعلیم مدل‌های از پیش تعلیم یافته (انتقال یادگیری) به عنوان یکی از روش‌های پیاده‌سازی یادگیری عمیق نتایج قابل قبولی در ارزیابی تصاویر و خرابی ترک خورده‌گی روسازی دارد. به ویژه در مواقعي که داده‌های زیادی به منظور تعلیم مدل‌ها در دسترس

توجهی از آن‌ها در زمینه تشخیص خودکار خرابی‌های روسازی با توجه به داده‌های برداشت شده از شبکه روسازی بوده است. در بین خرابی‌های روسازی، خرابی ترک خورده‌گی یکی از رایج‌ترین خرابی‌ها است و اثرات مخرب زیادی در سطح کیفی روسازی دارد. در این مقاله ضمن تشریح مباحث تئوری با به کارگیری داده کاوی و یادگیری ماشین، هشت مدل مبتنی بر شبکه‌های پیچشی عمیق به روش انتقال یادگیری برای تشخیص و دسته‌بندی ترک‌های روسازی ایجاد شد و عملکرد هر یک از مدل‌ها از جنبه‌های مختلف نظری سرعت یادگیری، سرعت اجرا (ارزیابی) و دقت مورد ارزیابی و مقایسه قرار گرفت. ارزیابی جامع مدل‌های تولید شده در این پژوهش با در نظر گرفتن تمامی پارامترهای عملکردی (سرعت یادگیری، سرعت ارزیابی و دقت) در شکل ۱۸ ارائه شده است که در این شکل مساحت حباب‌ها و محور افقی به ترتیب بیانگر سرعت ارزیابی و یادگیری مدل به ازای هر تصویر است و محور قائم بیانگر معیار F-score به عنوان معیار جامع ارزیابی دقت و صحت مدل است.

بدیهی است که در شکل ۱۸ هرچه حباب‌ها کوچک‌تر باشند و مکان آن‌ها بالاتر و به سمت چپ متمایل‌تر باشد بیانگر عملکرد بهتر مدل‌ها خواهد بود. بر همین اساس در این پژوهش مدل SqueezeNet بهترین عملکرد را با سرعت ۰/۴۴۲ ثانیه به ازای

ساده یا روش های مبتنی بر پردازش تصویر می تواند موضوع مناسبی برای مطالعات آینده باشد.

مراجع

- [1] Y. Shi, S. Guo, P. Sun, The role of infrastructure in China's regional economic growth, *Journal of Asian Economics*, 49 (2017) 26-41.
- [2] E. Ivanova, J. Masarova, Importance of road infrastructure in the economic development and competitiveness, *Economics Management*, 18(2) (2013) 263-274.
- [3] R. Engström, The Roads' Role in the Freight Transport System, *Transportation Research Procedia*, 14 (2016) 1443-1452.
- [4] C.Y. Chan, B. Huang, X. Yan, S. Richards, Investigating effects of asphalt pavement conditions on traffic accidents in Tennessee based on the pavement management system (PMS), *Journal of advanced transportation*, 44(3) (2010) 150-161.
- [5] ASCE, 2017 infrastructure report card, Roads, ASCE Reston, VA, 2017.
- [6] M.Y. Shahin, Pavement management for airports, roads, and parking lots, 1994.
- [7] H. Zakeri, F.M. Nejad, A. Fahimifar, Image Based Techniques for Crack Detection, Classification and Quantification in Asphalt Pavement: A Review, *Archives of Computational Methods in Engineering*, 24(4) (2017) 935-977.
- [8] H. Zakeri, F.M. Nejad, A. Fahimifar, Rahbin: A quadcopter unmanned aerial vehicle based on a systematic image processing approach toward an automated asphalt pavement inspection, *Automation in Construction*, 72(Part 2) (2016) 211-235.
- [9] C. Koch, K. Georgieva, V. Kasireddy, B. Akinci, P. Fieguth, A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure, *Advanced Engineering Informatics*, 29(2) (2015) 196-210.
- [10] T.B. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017) 1374822.

نباشد.

- مشخصه های مدل های از پیش تعلیم یافته (عمق، تعداد پارامتر ها و ...) تاثیر زیادی در عملکرد مدل های ایجاد شده به روش انتقال یادگیری خواهد داشت.

- آماده سازی داده ها مهمترین گام در به کارگیری دانش داده کاوی و یادگیری ماشین است و تاثیر مستقیم در نتایج بدست آمده خواهد داشت. به عبارت دیگر هرچه داده های غنی تر و متنوع تر برای عملیات یادگیری استفاده شود نتایج بهتری از مدل های ساخته شده به دست خواهد آمد.

- به طور کلی تصمیم گیری در مورد استفاده از مدل ها و روش یادگیری مدل ها به عواملی نظیر توان سیستم پردازشی، میزان و کیفیت داده های موجود و میزان سطح عملکرد(سرعت و دقت) مورد نیاز بستگی دارد.

۵-۱- مطالعات آینده

در این بخش با توجه به انجام پژوهش حاضر، ضرورت انجام پژوهش های بیشتر احساس می شود و بر همین اساس چند پیشنهاد ارائه می گردد.

- پارامتر های اساسی یادگیری نظیر تعداد دوره ها، نرخ یادگیری، تعداد تکرار و ... تاثیر بسیار زیادی در زمان و کیفیت یادگیری مدل ها دارند و در اغلب مطالعات به صورت تجربی و با سعی و خطأ تعیین می شوند و این نیاز احساس می شود که تحقیقاتی با هدف بهینه سازی این پارامتر ها صورت گیرد.

- 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 خرابی های روسازی 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

- Journal of computing in civil engineering, 30(6) (2016) 04016015.
- [21] M. Solla, S. Lagüela, H. González-Jorge, P. Arias, Approach to identify cracking in asphalt pavement using GPR and infrared thermographic methods: Preliminary findings, NDT & E International, 62 (2014) 55-65.
- [22] H. Song, K. Baek, Y. Byun, Pothole detection using machine learning, Advanced science and technology letters, 150 (2018) 151-155.
- [23] M.R. Carlos, M.E. Aragón, L.C. González, H.J. Escalante, F. Martínez, Evaluation of Detection Approaches for Road Anomalies Based on Accelerometer Readings--Addressing Who's Who, IEEE Transactions on Intelligent Transportation Systems, (2018).
- [24] A. Fox, B.V. Kumar, J. Chen, F. Bai, Multi-lane pothole detection from crowdsourced undersampled vehicle sensor data, IEEE Transactions on Mobile Computing, 16(12) (2017) 3417-3430.
- [25] S. Nakashima, S. Aramaki, Y. Kitazono, S. Mu, K. Tanaka, S. Serikawa, Application of ultrasonic sensors in road surface condition distinction methods, Sensors, 16(10) (2016) 1678.
- [26] A. Bystrov, E. Hoare, T.-Y. Tran, N. Clarke, M. Gashinova, M. Cherniakov, Road surface classification using automotive ultrasonic sensor, Procedia Engineering, 168 (2016) 19-22.
- [27] R. Madli, S. Hebbar, P. Pattar, V. Golla, Automatic detection and notification of potholes and humps on roads to aid drivers, IEEE Sensors Journal, 15(8) (2015) 4313-4318.
- [28] J. Mehta, V. Mathur, D. Agarwal, A. Sharma, K. Prakasha, Pothole Detection and Analysis System (Pol AS) for Real Time Data Using Sensor Networks, Journal of Engineering and Applied Sciences, 12(12) (2017) 3090-3097.
- [29] J. Huang, W. Liu, X. Sun, A pavement crack detection method combining 2D with 3D information based on Dempster-Shafer theory, Computer-Aided Civil Infrastructure Engineering, 29(4) (2014) 299-313.
- [30] G. Zhou, L. Wang, D. Wang, S. Reichle, Integration of GIS and data mining technology to enhance the pavement [11] N.-D. Hoang, An Artificial Intelligence Method for Asphalt Pavement Pothole Detection Using Least Squares Support Vector Machine and Neural Network with Steerable Filter-Based Feature Extraction, Advances in Civil Engineering, 2018 (2018) 12.
- [12] P. Wang, Y. Hu, Y. Dai, M. Tian, Asphalt Pavement Pothole Detection and Segmentation Based on Wavelet Energy Field, Mathematical Problems in Engineering, 2017 (2017) 13.
- [13] B. Mataei, F. Moghadas Nejad, M. Zahedi, H. Zakeri, Evaluation of pavement surface drainage using an automated image acquisition and processing system, Automation in Construction, 86 (2018) 240-255.
- [14] F.M. Nejad, N. Karimi, H. Zakeri, Automatic image acquisition with knowledge-based approach for multi-directional determination of skid resistance of pavements, Automation in Construction, 71(Part 2) (2016) 414-429.
- [15] K. Kamal, S. Mathavan, T. Zafar, I. Moazzam, A. Ali, S.U. Ahmad, M. Rahman, Performance assessment of Kinect as a sensor for pothole imaging and metrology, International Journal of Pavement Engineering, 19(7) (2018) 565-576.
- [16] Y.-C. Tsai, A. Chatterjee, Pothole Detection and Classification Using 3D Technology and Watershed Method, Journal of Computing in Civil Engineering, 32(2) (2017) 04017078.
- [17] J.Y.-C. Tsai, Z.-H. Wang, F. Li, Assessment of rut depth measurement accuracy of point-based rut bar systems using emerging 3d line laser imaging technology, Journal of Marine Science and Technology, 23(3) (2015) 322-330.
- [18] J.Y.-C. Tsai, F. Li, Y.-C. Wu, A new rutting measurement method using emerging 3D line-laser-imaging system, International Journal of Pavement Research and Technology, 6(5) (2013) 667-672.
- [19] S. Dai, K. Hoegh, 3D step frequency GPR Asphalt pavement stripping detection: Case study evaluating filtering approaches, in: Advanced Ground Penetrating Radar (IWAGPR), 2017 9th International Workshop on, IEEE, 2017, pp. 1-7.
- [20] S. Li, C. Yuan, D. Liu, H. Cai, Integrated processing of image and GPR data for automated pothole detection,

- Radon transform, Advanced Engineering Informatics, 30(3) (2016) 481-499.
- [43] V. Ananth, P. Ananthi, V. Elakkiya, J. Priyadarshini, R. Shiyamili, Automatic Pavement Crack Detection Algorithm, International Innovative Research Journal of Engineering and Technology, 2 (2017).
- [44] I.H. Witten, E. Frank, M.A. Hall, C.J. Pal, Data Mining: Practical machine learning tools and techniques, Morgan Kaufmann, 2016.
- [45] J. Han, J. Pei, M. Kamber, Data mining: concepts and techniques, Elsevier, 2011.
- [46] F. Gorunescu, Data Mining: Concepts, models and techniques, Springer Science & Business Media, 2011.
- [47] E. Alpaydin, Introduction to machine learning, MIT press, 2009.
- [48] A.T. Azar, S. Vaidyanathan, Computational intelligence applications in modeling and control, Springer, 2015.
- [49] S.B. Kotsiantis, I. Zaharakis, P. Pintelas, Supervised machine learning: A review of classification techniques, 160 (2007) 3-24.
- [50] I. Goodfellow, Y. Bengio, A. Courville, Y. Bengio, Deep learning, MIT press Cambridge, 2016.
- [51] M.M. Najafabadi, F. Villanustre, T.M. Khoshgoftaar, N. Seliya, R. Wald, E. Muhamemagic, Deep learning applications and challenges in big data analytics, Journal of Big Data, 2(1) (2015) 1.
- [52] R. Vidal, J. Bruna, R. Giryes, S. Soatto, Mathematics of deep learning, arXiv preprint arXiv:04741, (2017).
- [53] T. Wiatowski, H. Bölcskei, A mathematical theory of deep convolutional neural networks for feature extraction, IEEE Transactions on Information Theory, 64(3) (2018) 1845-1866.
- [54] A. Bhandare, M. Bhide, P. Gokhale, R. Chandavarkar, Applications of Convolutional Neural Networks, International Journal of Computer Science Information Technologies, (2016) 2206-2215.
- [55] S. Albelwi, A. Mahmood, A framework for designing the architectures of deep convolutional neural networks, Entropy, 19(6) (2017) 242.
- [56] Y. LeCun, Y. Bengio, Convolutional networks for management decision making, Journal of Transportation Engineering, 136(4) (2009) 332-341.
- [31] K. Gopalakrishnan, Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review, Data, 3(3) (2018) 28.
- [32] Y. LeCun, Y. Bengio, G. Hinton, Deep learning, Nature, 521 (2015) 436.
- [33] C. Robert, Machine Learning, a Probabilistic Perspective, CHANCE, 27(2) (2014) 62-63.
- [34] N.K. Warrier, K. Sathish, Object Detection on Roads using Deep Learning and Neural Networks, Journal of Network Communications Emerging Technologies 8(4) (2018).
- [35] M. Kantardzic, Data mining: concepts, models, methods, and algorithms, John Wiley & Sons, 2011.
- [36] K. Gopalakrishnan, S.K. Khaitan, A. Choudhary, A. Agrawal, Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection, Construction and Building Materials, 157 (2017) 322-330.
- [37] L. Deng, D. Yu, Deep learning: methods and applications, Foundations Trends® in Signal Processing, 7(3-4) (2014) 197-387.
- [38] Y. LeCun, Y. Bengio, G.J.n. Hinton, Deep learning, 521(7553) (2015) 436.
- [39] S. Dorafshan, R.J. Thomas, M. Maguire, Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete, Construction and Building Materials, 186 (2018) 1031-1045.
- [40] Z. Tong, J. Gao, Z. Han, Z. Wang, Recognition of asphalt pavement crack length using deep convolutional neural networks, Road Materials and Pavement Design, 19(6) (2018) 1334-1349.
- [41] Q. Zhu, Pavement crack detection algorithm Based on image processing analysis, in: Proceedings - 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2016, 2016, pp. 15-18.
- [42] Y.O. Ouma, M. Hahn, Wavelet-morphology based detection of incipient linear cracks in asphalt pavements from RGB camera imagery and classification using circular

- [67] Z. Tong, J. Gao, H. Zhang, Innovation for evaluating aggregate angularity based upon 3D convolutional neural network, *Construction and Building Materials*, 155 (2017) 919-929.
- [68] M.A. Nielsen, *Neural networks and deep learning*, Determination press USA, 2015.
- [69] H. Eom, H. Choi, Alpha-Pooling for Convolutional Neural Networks, *arXiv preprint arXiv:03436*, (2018).
- [70] D.C. Ciresan, U. Meier, J. Masci, L. Maria Gambardella, J. Schmidhuber, Flexible, high performance convolutional neural networks for image classification, in: *IJCAI Proceedings-International Joint Conference on Artificial Intelligence*, Barcelona, Spain, 2011, pp. 1237.
- [71] L. Li, K. Jamieson, G. DeSalvo, A. Rostamizadeh, A. Talwalkar, Hyperband: A novel bandit-based approach to hyperparameter optimization, *The Journal of Machine Learning Research*, 18(1) (2017) 6765-6816.
- [72] S.R. Young, D.C. Rose, T.P. Karnowski, S.-H. Lim, R.M. Patton, Optimizing deep learning hyper-parameters through an evolutionary algorithm, in: *Proceedings of the Workshop on Machine Learning in High-Performance Computing Environments*, ACM, 2015, pp. 4.
- [73] T. Domhan, J.T. Springenberg, F. Hutter, Speeding Up Automatic Hyperparameter Optimization of Deep Neural Networks by Extrapolation of Learning Curves, in: *IJCAI*, 2015, pp. 3460-3468.
- [74] J. Snoek, H. Larochelle, R.P. Adams, Practical bayesian optimization of machine learning algorithms, in: *Advances in neural information processing systems*, 2012, pp. 2951-2959.
- [75] Y. Gao, K.M. Mosalam, Deep Transfer Learning for Image-Based Structural Damage Recognition, 33(9) (2018) 748-768.
- [76] K. Zhang, H. Cheng, A Novel Pavement Crack Detection Approach Using Pre-selection Based on Transfer Learning, in: Y. Zhao, X. Kong, D. Taubman (Eds.) *Image and Graphics*, Springer International Publishing, Cham, 2017, pp. 273-283.
- [77] S.J. Pan, Q. Yang, A survey on transfer learning, *IEEE Transactions on knowledge data engineering*, 22(10) images, speech, and time series, *The handbook of brain theory neural networks*, 3361(10) (1995) 1995.
- [57] K. Zhang, H. Cheng, B. Zhang, Unified Approach to Pavement Crack and Sealed Crack Detection Using Preclassification Based on Transfer Learning, *Journal of Computing in Civil Engineering*, 32(2) (2018) 04018001.
- [58] T. Wang, K. Gopalakrishnan, O. Smadi, A.K.J.T. Soman, Automated shape-based pavement crack detection approach, 33(3) (2018) 598-608.
- [59] D. Seichter, M. Eisenbach, R. Stricker, G. H-M, How to Improve Deep Learning based Pavement Distress Detection while Minimizing Human Effort, in: *Proc. Int. Conf. on*, 2018, pp. 63-70.
- [60] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiyama, H. Omata, Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone, *arXiv preprint arXiv:1801.09454*, (2018).
- [61] B. Li, K.C. Wang, A. Zhang, E. Yang, G. Wang, Automatic classification of pavement crack using deep convolutional neural network, *International Journal of Pavement Engineering*, (2018) 1-7.
- [62] G. Ciaparrone, A. Serra, V. Covito, P. Finelli, C.A. Scarpato, R. Tagliaferri, A Deep Learning Approach for Road Damage Classification, in: *Advanced Multimedia and Ubiquitous Engineering*, Springer, 2018, pp. 655-661.
- [63] Z. Tong, J. Gao, H. Zhang, Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks, *Construction and Building Materials*, 146 (2017) 775-787.
- [64] Y. Liu, J. Yao, X. Lu, R. Xie, L. Li, DeepCrack: A Deep Hierarchical Feature Learning Architecture for Crack Segmentation, *Neurocomputing*, (2019).
- [65] J. Singh, S. Shekhar, Road Damage Detection And Classification In Smartphone Captured Images Using Mask R-CNN, *arXiv*, (2018).
- [66] K. Gopalakrishnan, H. Gholami, A. Vidyadharan, A. Choudhary, A. Agrawal, Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model, *International Journal for Traffic Transport Engineering*, 8 (2018) 1.

- size, (2016).
- [83] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770-778.
- [84] G. Huang, Z. Liu, L. Van Der Maaten, K.Q. Weinberger, Densely connected convolutional networks, in: CVPR, 2017, pp. 3.
- [85] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, Rethinking the inception architecture for computer vision, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 2818-2826.
- [86] F.M. Nejad, H. Zakeri, An optimum feature extraction method based on Wavelet–Radon Transform and Dynamic Neural Network for pavement distress classification, Expert Systems with Applications, 38(8) (2011) 9442-9460.
- [87] F. Moghadas Nejad, H. Zakeri, An expert system based on wavelet transform and radon neural network for pavement distress classification, Expert Systems with Applications, 38(6) (2011) 7088-7101.
- [88] R.C. Gonzalez, R.E. Woods, Digital image processing, 2 (2007).
- (2010) 1345-1359.
- [78] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, Imagenet large scale visual recognition challenge, International Journal of Computer Vision, 115(3) (2015) 211-252.
- [79] A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, in: Advances in neural information processing systems, 2012, pp. 1097-1105.
- [80] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9.
- [81] K. He, X. Zhang, S. Ren, J. Sun, Delving deep into rectifiers: Surpassing human-level performance on imagenet classification, in: Proceedings of the IEEE international conference on computer vision, 2015, pp. 1026-1034.
- [82] F.N. Iandola, S. Han, M.W. Moskewicz, K. Ashraf, W.J. Dally, K.J.a.p.a. Keutzer, SqueezeNet: Alexnet-level accuracy with 50x fewer parameters and< 0.5 mb model

چگونه به این مقاله ارجاع دهیم

S. Ranjbar, F. Moghadas Nejad, H. Zakeri, Pavement cracks detection and classification using deep convolutional networks, Amirkabir J. Civil Eng., 52(9) (2020) 2255-2278.

DOI: [10.22060/ceej.2019.16103.6133](https://doi.org/10.22060/ceej.2019.16103.6133)

