

شناسایی ترک در اعضاء بتنی با استفاده از مدل‌های رمزگذار - رمزگشایی بر پایه‌ی یادگیری عمیق

محمد موسوی (دانشجوی کارشناسی ارشد)

علی بخشی * (دانشیار)

دانشکده‌ی هندسی عمران، دانشگاه صنعتی شریف

مهندنسی عمران شریف، (ایران ۱۴۰۱)، (آزاد ۷۸-۷۹، خیابان ۱۳۰-۱۳۱، پژوهشی)

شناسایی ترک از مسائل ضروری و بنیادی زمینه‌ی پایش سلامت سازه‌های مهندسی است. پژوهش حاضر به ارائه مدلی بر پایه یادگیری عمیق پرداخته است، که به واسطه‌ی آن بتوان فریند شناسایی ترک در سطوح بتی را به صورت خودکار به انجام رساند. برای رسیدن به بیشترین دقت و همچنین کاهش زمان آموزش مدل از آموزش انتقالی در رویکرد آموزش استفاده شده است. استفاده از انواع روش‌های داده‌افزایی، کمک شایانی به توانایی مدل در مواجه با شرایط تصویربرداری و نووفه‌های موجود در تصاویر کرده است. مدل مورد نظر با استفاده از یک مجموعه داده‌ی برچسب‌گذاری شده آموزش دیده و دقت نهایی بر اساس پارامتر ارزیابی اصلی پژوهش برابر $91/38\%$ گزارش شده است. روش موجود نسبت به روش‌های پیشین پردازش تصویری، دقت بسیار بالاتری دارد و همچنین وجود انواع ترک در مجموعه‌ی داده استفاده شده کمک می‌کند که مدل برای انواع ترک‌ها قابلیت تعمیم داشته باشد و از دقت و کیفیت بخش‌بندی آن کاسته نشود.

mohammad.mousavi@sharif.edu
bakhti@sharif.edu

واژگان کلیدی: پایش سلامت سازه‌ها، یادگیری عمیق، بینایی رایانه، یادگیری ماشین، تشخیص ترک.

۱. مقدمه

پیدایش مبحث یادگیری عمیق^۱، به یکی از مباحث مورد توجه در پایش سلامت سازه‌ها مبدل شده است. در گذشته، پردازش تصاویر عمده‌ای با استفاده از روش‌های سنتی، همچون لبیاب‌ها^۲ و تبدیل‌های حوزه‌ی بسامدی مانند فوریه انجام شده است. مطالعات زیادی در جهت اتوپاسیون پایش بصری سازه‌ها، روش‌های اخیر را به کار برداشته‌اند.^[۳-۶] اگرچه روش‌های سنتی در دوره‌ی بیرونی مورد استقبال گسترش بوده‌اند، اما ضعف‌هایی مانند حساسیت بسیار زیاد نسبت به وجود نوافه و همچنین سرعت پردازش بسیار کم، امکان بهره‌گیری عملی از آنها را غیرممکن ساخته است. از سال ۲۰۱۲، با ظهور شاخه‌ی یادگیری عمیق و توسعه‌ی شبکه‌های عصبی کانولوشن^۳، تحولی شگرف در حوزه‌ی بینایی رایانه صورت گرفته است، که این تحول به سرعت وارد تمامی رشته‌های مرتبط با پردازش تصاویر نیز شده است. پایش سلامت سازه‌ها نیز از قاعده‌ی مذکور مستثنی نبوده و در سال‌های اخیر مطالعات بسیاری پیرامون استفاده از یادگیری عمیق در پایش سلامت سازه‌ها صورت گرفته است. در ابتدا، چا^۴ و همکاران^[۷] با استفاده از یادگیری عمیق و فرایند دسته‌بندی^۵ توانستند به طور تخمینی الگوی ترک را در اعضاء بتنی تشخیص دهند. اگرچه مدل ابتدایی مذکور، دقت بسیار کمی داشت، اما سرآغاز مطالعات بسیاری بوده است، که به نتایج دقیق‌تری منجر شده است. ایشان پس از آن در پژوهش دیگری در سال ۲۰۱۸^[۸] با استفاده از یک شبکه‌ی عصبی کانولوشن تأثیم‌محور^۶ توانستند نواحی وجود ترک را با دقت بیشتری استخراج کنند. پس از آن، گوپالاکریشان^۷ و همکاران^[۹] با

زیساخته‌ها و سازه‌های پراهمیت، همچون: پل‌ها، سدها، تونل‌ها و آسمان‌خراش‌ها، در مواجهه با عواملی چون: زلزله، شرایط جوی، افزایش عمر، خستگی ناشی از بارگذاری‌های دوره‌یی و غیره، کاهش شدیدی در میزان باربری خود را تجربه می‌کنند. از اولین نشانه‌های بروز آسیب در سازه‌ها (به خصوص سازه‌های بتی) می‌توان به پیدایش ترک‌ها اشاره کرد. مطالعات اخیر نشان داده‌اند که ترک‌ها می‌توانند به بروز ناپیوستگی و همچنین کاهش سختی اعضاء سازه‌یی منجر شوند.^[۱۰-۱۱] لذا تشخیص به موقع ترک‌ها در سازه، ضرورت بسیار بالاتی دارد. در سال‌های اخیر، پایش سلامت سازه‌ها^۱، کمک شایانی در تشخیص به موقع ترک‌ها داشته است. البته حس‌گرهای رایج در فرایند پایش سلامت همچون پیزووالکتروک^۲ یا فیرنوری^۳ می‌توانند هزینه‌های زیادی با خود به همراه داشته باشند. علاوه بر این، تعداد بینه‌ی حس‌گرهای پایش تمامی قسمت‌های سازه، همواره یکی از چالش‌های موجود در این مبحث بوده است. با توجه به چالش‌های اخیر، پایش بصری سازه‌ها همواره به عنوان جزئی ضروری از پایش سلامت سازه‌ها مطرح بوده است. با توجه به چالش‌ها و خطاهای مرتبط با پایش بصری سازه‌ها، روش‌های مختلف پردازش تصویری، همواره به عنوان یک راه حل برای اتوپاسیون فرایند مذکور مطرح بوده است. این حوزه از پایش سلامت سازه‌ها (پردازش تصویری، در سال‌های اخیر با توسعه‌ی هوش مصنوعی و به خصوص

* نویسنده مسئول

تاریخ: دریافت ۲۷/۹/۱۴۰۰، اصلاحیه ۱۷/۱/۱۴۰۱، پذیرش ۲۳/۱/۱۴۰۱.

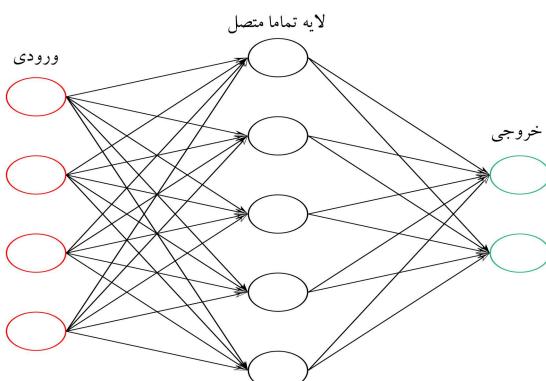
DOI:10.24200/J30.2022.59496.3055

شده است. یادگیری انتقالی، روش استفاده شده در آموزش مدل است که تأثیر به سریعی در افزایش سرعت یادگیری دارد و همچنین، تعداد داده‌ی مورد نیاز جهت آموزش مدل کاهش می‌باشد، که این موضوع در بحث بخش‌بندی تصویر با توجه به فرایند زمانی برچسب‌گذاری دستی داده‌های آموزش، بسیار مفید است.

۲. روش‌های استفاده شده

در بخش کنونی، به توضیح مختصری از روش استفاده شده در پژوهش حاضر پرداخته شده است. روش استفاده شده در پژوهش حاضر، یادگیری عمیق در حقیقت زیراخاهی نوین از شاخه‌ی یادگیری ماشین است. استفاده از یادگیری ماشین، از دیرباز در حل مسائل مهندسی رواج داشته است. شبکه‌های عصبی نمونه‌یی شاخص و بسیار کاربردی از مدل‌های یادگیری ماشین هستند، که در حل مسائل مختلف استفاده می‌شوند. با توجه به این که مدل استفاده شده در مطالعه‌ی حاضر، حالتی پیشرفته و تعمیم‌یافته از شبکه‌های عصبی است، توضیحی مختصر از عملکرد شبکه‌های عصبی ارائه شده است.

در شکل ۱، که نمایی بسیار ساده از یک شبکه‌ی عصبی است، مکانیزم عملکرد شبکه‌های عصبی مشاهده می‌شود. در حل مسائل مرتبط با شبکه‌ی عصبی، داده‌ی ورودی مسئله مشخص است، داده‌ی خروجی نیز می‌تواند با کمک آزمایش و یا نظر کارشناسی مشخص شود، اما فرمول بندی مشخصی ما بین مقادیر ورودی و خروجی به سادگی قابل استخراج نیست. در حل چنین مسائلی، شبکه‌ی عصبی می‌تواند راه‌آشنا باشد؛ بدین ترتیب که تعداد زیادی از مقادیر ورودی و خروجی به صورت بردارهایی از داده‌ها تعریف می‌شوند و یک لایه‌ی شبکه‌ی عصبی (مانند شکل ۱) در تمام عناصر بردار ورودی مذکور ضرب و در نهایت بردار خروجی مدل حاصل می‌شود. یادگیری ماشین به زبان ساده عبارت است از بهینه کردن مقادیر موجود در عناصر این لایه‌ی میانی (ایه‌ی پنهان) به صورتی که حاصل ضرب آن در بردار ورودی، بردار خروجی را حاصل کند. این فرایند بهینه‌سازی، که به آموزش مدل شناخته می‌شود، توسط یک الگوریتم بهینه‌ساز^{۱۸} و با کمک یکتابع هزینه انجام می‌بزیرد؛ بدین صورت که در هر مرحله از آموزش، الگوریتم بهینه‌ساز مقادیری برای لایه‌ی پنهان پیشنهاد می‌کند و پس از ضرب شدن بردار در بردارهای ورودی و استخراج خروجی، اختلاف خروجی به دست آمده با خروجی واقعی که در دسترس بوده است (مقدار هزینه)، محاسبه می‌شود و این فرایند ادامه پیدا می‌کند، تا این‌که مقادیر هزینه به کمترین مقدار ممکن برسد. پس از کامل شدن فرایند آموزش و ارزیابی عملکرد مدل، می‌توان با اتکا به مدل مذکور، مقادیر



شکل ۱. نمایی ساده از عملکرد یک شبکه‌ی عصبی.

در مطالعه‌یی بر روی دسته‌بندی تصاویر جهت تشخیص ترک در تصویر برخلاف مدل‌های قبلی، از یادگیری انتقالی^{۱۹} استفاده کردند، که مدل استفاده شده‌ی ایشان، یکی از مدل‌های معروف شبکه‌ی عصبی کانولوشنی با نام VGG ۱۶^[۱۰] بوده است، که بر روی مجموعه‌ی داده‌ی تصویری Image-net^[۱۱] آموزش دیده است. در

فرایند یادگیری انتقالی استفاده شده در مطالعه‌ی آخر، قسمتی از مدل که قرار است ویژگی‌های داده‌ی تصویری را استخراج کند، به صورت از پیش آموزش یافته برای مدل تعریف می‌شود و مدل فقط برای لایه‌های نهایی، که مربوط به عملیات دسته‌بندی است، آموزش می‌بیند. بدین ترتیب قسمت عظیمی از بار محاسباتی وارده برای آموزش مدل کاسته می‌شود. با توجه به این که مدل‌های از پیش آموزش دیده‌ی مذکور بر روی مجموعه‌ی داده‌های بزرگ و فرآگیری آموزش دیده‌اند، در صورت عدم تغییر محسوسی در عملکرد آنها مشاهده شود.

تا این‌جا بیشتر مطالعات ذکر شده بر روی فرایندهای دسته‌بندی و یا تشخیص ترک، که فقط ناحیه‌ی وقوع ترک را تخمین می‌زنند، تمرکز داشته‌اند؛ در صورتی که فرایند پایش سلامت، نیاز به دقت بالایی برای مکان‌یابی ترک‌های موردنظر دارد. با پیشرفت مطالعات در کاربرد یادگیری عمیق در پایش سلامت صری سازه‌ها، دانگ^{۱۲} و همکاران^(۱۹)^[۱۲] از یک شبکه‌ی تماماً کانولوشنی^{۱۳} استفاده کردند و فرایند بخش‌بندی یا تقسیم‌بندی معنایی^{۱۴} را بر روی داده‌های تصویری ترک بین انجام دادند. در فرایند بخش‌بندی، یک تصویر جدید با ابعاد تصویر ورودی ایجاد می‌شود، که در آن پس زمینه به رنگ سیاه است و نواحی ترک با رنگ سفید مشخص می‌شود؛ به عبارتی، یک تصویر دودویی^{۱۵} خواهد بود که نواحی زمینه با مقدار صفر و نواحی ترک با مقدار یک مشخص خواهند شد. این فرایند به عنوان فرایند دسته‌بندی در مقیاس پیکسل نیز شناخته می‌شود، چراکه در طی آن هر پیکسل از تصویر در یک دسته‌ی مخصوص به خود طبقه‌بندی می‌شود. مدل استفاده شده در پژوهش اخیر نوعی رمزگذار - رمزگشا^{۱۶} است، که در قسمت رمزگذار، تصویر دودویی جدید ایجاد و خروجی مدل حاصل می‌شود.

در ادامه، با توسعه‌ی نسل جدیدی از رمزگذار - رمزگشایها مدلی با نام U-Net^[۱۷] ارائه شده است، که اوایل برای استفاده در داده‌های پزشکی استفاده می‌شده است، ولی به دلیل توانایی بالای آن در امر بخش‌بندی تصاویر، به سرعت در سایر مسائل نیز به کار گرفته شده است. لیو^{۱۷} و همکاران^(۲۰)^[۱۷] با بهره‌گیری از مدل U-Net، فرایند بخش‌بندی تصویر را برای تشخیص ترک در بین انجام دادن و توانستن به دقت نزدیک به ۹۰٪ دست پیدا کنند. البته در مطالعه‌ی مذکور نیز چالش‌هایی موجود بوده است، از جمله این‌که داده‌های استفاده شده، شامل ترک‌هایی با الگوی یکسان و ضخامت‌های مشابه بوده است، که در تبیه‌ی آن، مدل نهایی در تشخیص ترک با ابعاد متفاوت با مشکل مواجه بوده است. همچنین رمزگذار استفاده شده در مدل U-Net ساختار بسیار ساده‌ی دارد، که در مقایسه با مدل‌های جدید، دقت نسبتاً کمتری دارد.

در پژوهش حاضر، فرایند بخش‌بندی تصاویر با استفاده از یادگیری عمیق برای شناسایی ترک در تصاویر اعضاء بتنی انجام شده است. برای رسیدن به نتایج دقیق‌تر از یک مجموعه‌ی داده‌ی جدیدتر استفاده شده است، که تفسیر دقیق‌تری از محتوای ترک‌ها را ارائه می‌دهد و شامل انواع مختلف ترک با ضخامت‌های متفاوت می‌شود. ضمناً مدل استفاده شده در پژوهش حاضر، یک مدل رمزگذار - رمزگشای U شکل است، که در قسمت رمزگذار آن از شبکه‌ی کانولوشنی RensNet^{۱۰}^[۱۵] که یکی از مدل‌های بسیار دقیق و معروف کانولوشنی در حوزه‌ی یادگیری عمیق است، استفاده

هر یک از آنها، یک لایه‌ی تجمعی^{۱۹} اضافه می‌شود، که برای کنترل تعداد پارامترها ضروری است. در شکل ۴، نحوه‌ی عملکرد لایه‌های تجمعی مشاهده می‌شود؛ که مطابق آن، فرایند تجمعی به دو صورت تجمعی بیشینه و تجمعی میانگین اعمال می‌شود، که در یادگیری عمیق، عموماً از حالت تجمعی بیشینه استفاده می‌شود.

فرایند تجمعی با هدف کاهش ابعاد خروجی هر لایه از مدل انجام می‌پذیرد. به طور مثال، در شکل ۴ که ابعاد تجمعی در آن برابر 2×2 است، ابعاد داده‌ی خروجی به نصف حالت اولیه کاهش پیدا کرده است.

آخرین قسمت از یک مدل شبکه‌ی عصبی کانولوشنال در حالت کلی، مطابق شکل ۳، از یک یا چند لایه‌ی تمام‌متصل تشکیل می‌شود، که فرایند دسته‌بندی داده را بر عهده دارد. البته این ساختار مختص حالت‌های عمومی مدل‌های کانولوشنال است، که برای مسائل دسته‌بندی تصاویر استفاده می‌شوند؛ در سایر مسائل همچون تشخیص اشیاء^{۲۰} و یا بخش‌بندی معنایی^{۲۱} تصاویر لازم است که تغییراتی در این قسمت نهایی مدل اعمال شود، که خروجی مطلوب حاصل شود. به طور مثال، در مدل‌های استفاده شده در مسائل بخش‌بندی، که موضوع بحث پژوهش حاضر نیز است، استفاده از لایه‌های رمزگشای^{۲۲} رایج است، که عملی عکس لایه‌های کانولوشن پیشین انجام می‌دهند و در چیدمان متقارن با لایه‌های قبل از خود، اصطلاحاً یک مدل رمزگذار-رمزگشای^{۲۳} را تشکیل می‌دهند.

همان‌گونه که پیشتر اشاره شد، در پژوهش حاضر فرایند بخش‌بندی تصویر برای تصاویر ترک اعضاء بتنی به انجام رسیده است. اگرچه مدل‌های رایج شبکه‌ی عصبی عمده‌تاً با هدف حل مسائل دسته‌بندی توسعه داده می‌شوند، اما قسمت استخراج ویژگی^{۲۴} مدل‌های مذکور برای تعامل بینایی بینایی رایانه یک شبکه‌ی عصبی کانولوشن است. در بخش بعد، توضیحاتی در مورد مدل استفاده شده در پژوهش حاضر ارائه شده است.

۱.۲. مدل استفاده شده

در مطالعه‌ی حاضر، از یک مدل رمزگذار-رمزگشای U شکل استفاده شده است، که یکی از موفق‌ترین مدل‌های در زمینه‌ی بخش‌بندی تصاویر است. این دسته از مدل‌های (رمزگذار-رمزگشای)، از یک رمزگذار تشکیل می‌شود، که عموماً یک مدل شبکه‌ی عصبی کانولوشن است، که از قسمت دسته‌بندی کمترین^{۲۵} آن صرف نظر و فقط قسمت استخراج ویژگی به عنوان رمزگذار مدل وارد شده است. همچنین برای رسیدن به برچسب دودویی مورد نظر برای عملیات بخش‌بندی تصویر، یک رمزگشای وظیفه‌ی

خروجی را برای داده‌های محاسبه کرد، که هیچ اطلاعی از خروجی آنها در دست نیست.

اگرچه شبکه‌های عصبی قادر به حل بسیاری از مسائل هستند، یک محدودیت همواره آنها را دچار مشکل می‌کند. همان‌گونه که در توضیحات قبل اشاره شد، داده‌ی ورودی به این مدل لازم است از نوع بردارهای یک بعدی باشد؛ لذا محدودیت اخیر، عملکرد شبکه‌های عصبی را در مواجهه با داده‌های دو یا چند بعدی با چالش فراوان همراه کرده است. یکی از مهم‌ترین داده‌هایی که شامل محدودیت مذکور است، داده‌ی تصویر است، که عموماً به صورت تاسیسورهای سه‌بعدی RGB در دسترس هستند و ارتباط بین عناصر آن در هر سه بعد برقرار است و لذا تبدیل آن به بردارهای ستونی باعث ازین رفتن بخشی از ارتباط بین عناصر می‌شود. در چنین داده‌هایی، استفاده از شبکه‌های عصبی کانولوشنال به جای شبکه‌های عصبی ساده توصیه می‌شود. در شبکه‌ی عصبی ساده، به جای این که عملکرد به صورت ستونی تعریف شود، به صورت ماتریس‌های کوچک دو یا سه بعدی (کرنل یا فیلتر) تعریف می‌شود، فرایند کانولوشن برای یک داده دو بعدی در شکل ۲ مشاهده می‌شود.

در شکل ۲، هر درایه از ماتریس کانولوشن خروجی از مجموع حاصل ضرب یکای عناصر ماتریس کرنل در ماتریس ورودی حاصل شده است. در یک شبکه‌ی عصبی کانولوشنی، هر لایه از شبکه از تعدادی متغیر فیلتر (کرنل) کانولوشن تشکیل شده است، که به ترتیب بر ورودی اعمال می‌شوند. همچنین با توجه به پیچیدگی داده‌ی تصویر، لازم است که عملیات اخیر در مقیاس‌های مختلف انجام پذیرد؛ لذا یک شبکه‌ی عصبی کانولوشنی معمولاً از بر هم نه تعدادی لایه کانولوشنی ایجاد می‌شود. در شکل ۳، نمایی ساده از یک شبکه‌ی عصبی کانولوشن مشاهده می‌شود. مدل کانولوشن شکل ۳ از ۲ لایه کانولوشن تشکیل شده است، که پس از

۱	۳	۰	۱۰	۵
۰	۱	۰	۱	
۲	۰	۱	۰	
۲	۲	۰	۴	۱
۷	۱	۵	۳	۲

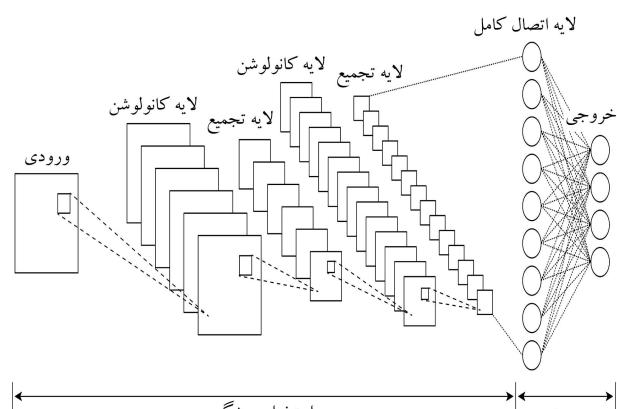
 \otimes

۲	۵	۰
۱	۰	۱
۰	۳	۱

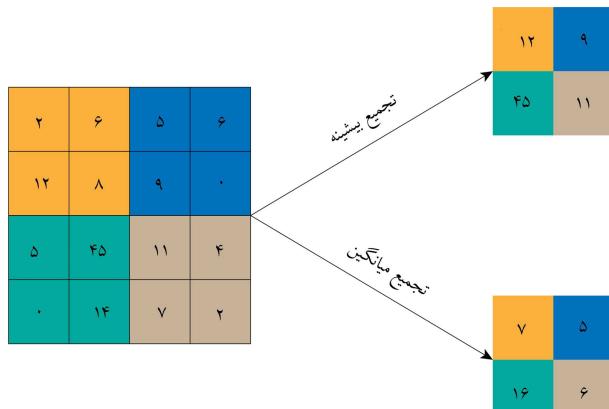
 $=$

۱۹	۱۱	۵۵
۱۴	۱۲	۱۶
۱۴	۲۹	۱۹

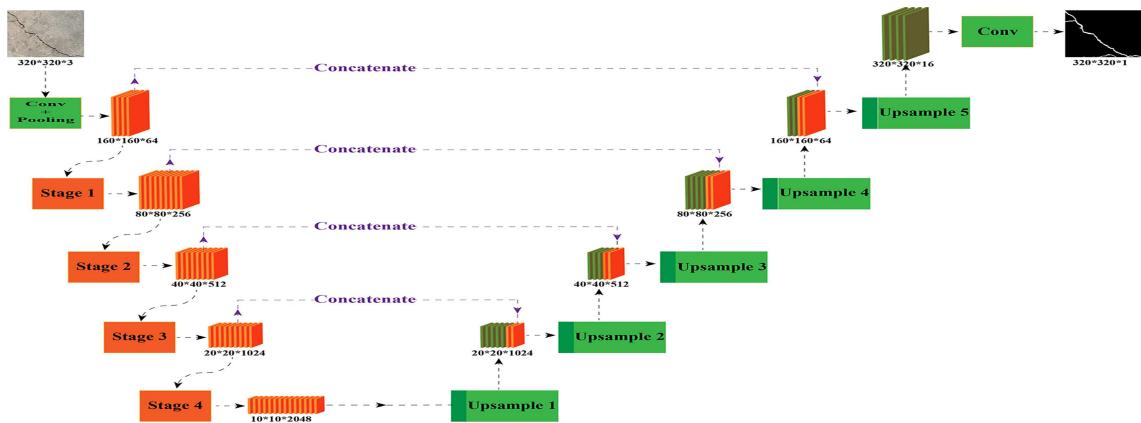
شکل ۲. فرایند کانولوشن در یک داده دو بعدی.



شکل ۳. نمایی ساده از یک شبکه‌ی عصبی کانولوشن.



شکل ۴. عملکرد لایه‌های تجمعی در شبکه‌های عصبی کانولوشن.



شکل ۵. معماری کلی مدل استفاده شده در پژوهش حاضر.

جدول ۱. جزئیات مدل ResNet^{۱۰۱} رمزگذار استفاده شده در مدل حاضر.

مرحله	ابعاد خروجی	ابعاد و تعداد فیلترها	لایه ای ابتدایی
۷ × ۷	۱۶۰ × ۱۶۰	۱	
	۸۰ × ۸۰	$\left\{ \begin{array}{l} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{array} \right\} \times 3$	
	۴۰ × ۴۰	$\left\{ \begin{array}{l} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{array} \right\} \times 4$	۲
	۲۰ × ۲۰	$\left\{ \begin{array}{l} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{array} \right\} \times 23$	۳
	۱۰ × ۱۰	$\left\{ \begin{array}{l} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{array} \right\} \times 3$	۴

۲. داده‌ی استفاده شده

در مطالعه‌ی حاضر، از یک مجموعه‌ی داده‌ی دسترسی آزاد با ۴۵۸ تصویر از سطوح بتنی دارای ترک استفاده شده است.^[۱۶] تصاویر موجود در مجموعه‌ی اخیر از ساختمان‌های مختلف در دانشگاه فنی خاورمیانه^[۷] در ترکیه گرفته شده و هر یک از آنها به صورت دستی برچسب‌گذاری و در قالب یک تصویر دودویی (سیاه و سفید) ارائه شده‌اند. نمونه‌هایی از تصاویر موجود در مجموعه‌ی ذکر شده به همراه برچسب‌های متناظر با هر یک در شکل ۶ مشاهده می‌شود.

از مجموعه داده‌ی اخیر تا کون مجموعه‌های ثانویه‌ی زیادی استخراج شده است، که از جمله‌ی آنها می‌توان به مجموعه‌ی ارائه شده توسط زانگ^[۲۸] و همکاران^(۲۰ ۱۶)،^[۱۷] که برای دسته‌بندی تصاویر استفاده می‌شود، اشاره کرد. ابعاد اصلی تصاویر در مجموعه‌ی داده‌ی استفاده شده در پژوهش حاضر برابر با (۳۰ ۲۴ × ۴۰ ۳۲) بوده است، که برای آموزش مدل بسیار بزرگ است و هزینه‌ی محاسباتی بسیار زیادی را تحمیل می‌کند؛ لذا تصاویر به اندازه‌ی (۳۲۰ × ۳۲۰) تبدیل و از تصاویر با ابعاد جدید برای آموزش مدل یادگیری عمیق استفاده شده است.

برگرداندن ابعاد را به مقادیر متناظر اولیه بر عهده دارد (در قسمت قبل ذکر شد) که واحد استخراج ویژگی در یک مدل شبکه‌ی عصبی کانولوشن برای کارکردن در مقیاس‌های مختلف، به صورت مرحله‌ی ابعاد را کاهش می‌دهد، لذا از اداده‌ی نهایی ایجاد شده در یک مدل شبکه‌ی عصبی کانولوشن نمی‌توان مستقیماً برای عملیات بخش‌بندی تصویر استفاده کرد).

در مدل ایجاد شده در مطالعه‌ی حاضر، شبکه‌ی عصبی کانولوشن ۱ ResNet^{۱۰۱} به عنوان رمزگذار و برای قسمت رمزگشای آن از رمزگشای پیشنهادی U-Net استفاده شده است. تفاوت مدل اخیر با مدل‌های ساده‌تر رمزگذار-رمزگشای در این است که در مدل‌های U شکل، اتصال‌هایی تعریف می‌شوند که عناصر موجود در رمزگذار را با عناصر ایجاد شده در رمزگشا مرتبط می‌سازد و بدین صورت نقشی اصلاحی در خروجی نهایی مدل ایفا می‌کند، که تأثیر به سزایی در دقت نهایی مدل دارد. معماری کلی مدل ساخته شده، در شکل ۵ مشاهده می‌شود.

قسمت رمزگذار مدل ResNet^{۱۰۱}، یکی از مدل‌های عمیق از خانواده‌ی مدل‌های ResNet است، که از چهار بخش اصلی تشکیل شده است، که هر یک آنها از واحدهای سه لایه‌ی کانولوشنی تشکیل شده‌اند، که مجموع لایه‌های موجود در مدل برابر با ۱۰۱ می‌شود. در جدول ۱، ترتیب و جزئیات مربوط به مدل ResNet^{۱۰۱} ارائه شده است. لازم به ذکر است که در مدل استفاده شده در پژوهش حاضر به لایه‌ی دسته‌بندی‌کننده نیاز نیست، در نتیجه، لایه‌ی دسته‌بندی‌کننده از معماری مدل حذف و مدل ارائه شده در جدول ۱۰۰ لایه دارد.

در ادامه، با توجه به این که ابعاد داده طی پنج مرحله کاهش پیدا کرده است، یک رمزگشای پنج مرحله‌یی به مدل اضافه شده و داده به یک تانسور با ابعاد اولیه‌ی (۳۲۰ × ۳۲۰) با ۱۶ کاتال بازگشته است. هر لایه از رمزگشای مذکور ابعاد داده را به دو برابر افزایش داده و پیکسل‌های جدید افزوده شده را با توجه به مقادیر موجود در داده‌ها پر کرده است.

در روش استفاده شده در مطالعه‌ی حاضر، برای بخش‌بندی تصاویر ترک، در مجموع دو برچسب برای اختصاص به پیکسل‌های تصاویر در نظر گرفته شده است: ترک و زمینه. با توجه به این موضوع، یک لایه‌ی کانولوشن، که وظیفه‌ی دسته‌بندی یک‌پیکسل‌ها را بر عهده دارد، به مدل افزوده شده است. در لایه‌ی مذکور از یک فعال‌ساز از نوع سیگموید^[۲۶]، که یکی از فعال‌سازهای رایج برای دسته‌بندی‌های دودویی است، استفاده می‌شود. در نهایت، خروجی مدل به صورت یک تصویر دودویی با مقادیر صفر و یک است، که پیکسل‌های با مقادیر صفر مربوط به زمینه و پیکسل‌های با مقادیر یک، محل ترک را مشخص می‌کنند.

با خطاهای زیادی مواجه می‌شود. حالتی فرض شود که قصد مسئله را برای دقت مطلق بهینه سازد؛ در این حالت اگر مدل، یک تصویر تمام‌سیاه (تمامی پیکسل‌ها برابر صفر) به عنوان خروجی دهد، با توجه به درصد کم پیکسل‌های ترک، دقیق نزدیک به $97/5\%$ حاصل می‌شود، در حالی که مدل هیچ‌گونه پیش‌بینی انجام نداده است و عملاً دقت مدل باید صفر گزارش شود. به همین علت ضروری است که از پارامترهای نسیی در سنجش دقت مدل مذکور استفاده شود. در پژوهش حاضر، از سه پارامتر اصلی که در مدل‌های بخش‌بندی تصویر به کار گرفته می‌شود، استفاده شده است، که عبارت‌اند از: صحت 35 ، فراخوانی 36 و دقت $F1^{37}$ ، که در ادامه، به توضیح مختصر آنها پرداخته شده است.

Precision: در مدل پیش رو هر چه مقدار صحت بیشتر باشد - احتمال وجود مشتبه‌های کاذب کمتر می‌شود. با توجه به این‌که در پژوهش حاضر مدل با پیکسل‌های ترک به عنوان مشتب (عدد ۱) و پیکسل‌های زمینه به عنوان منفی (عدد ۰) دسته‌بندی می‌شوند، با افزایش صحت مدل، احتمال تشخیص غلط پیکسل زمینه به عنوان ترک کمتر می‌شود. این پارامتر با استفاده از رابطه‌ی محاسبه می‌شود:

$$\Pr = \frac{TP}{TP + FP} \quad (1)$$

که در آن، $TP = ۳۸$ بیان‌گر تعداد پیکسل هایی است که ترک به درستی تشخیص داده شده است (مثبت صحیح)، $FP = ۳۹$ نیز بیان‌گر تعداد پیکسل هایی است که ترک تشخیص داده شده است، اما تشخیص صحیح نبوده است (مثبت کاذب). هدف نهایی در بهینه‌سازی پارامتر صحبت این است که هیچ پیکسلی به غلط در دسته‌تی ترک قرار نگیرد؛ لذا پیکسل های ترکی، که به غلط به عنوان زمینه در نظر گرفته شده‌اند، در پارامتر صحبت تغییری ایجاد نمی‌کنند. در نتیجه پارامتر صحبت نمی‌تواند به تهایی برای سنجش دقت نهایی مدل استفاده شود. بر این اساس پارامتر دیگری با عنوان حساسیت نیز تعریف می‌شود.

- فراخوانی یا حساسیت (Recall): پارامتر فراخوانی، که برای سنجش توانایی مدل در حدس پیکسل های ترک استفاده می شود، با استفاده از رابطه $\frac{2}{2}$ محاسبه می شود:

$$\text{Re} = \frac{TP}{TP + FN} \quad (1)$$

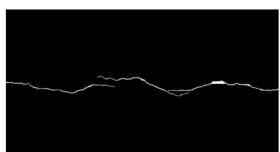
که در آن، FN^{۴۰} بیان‌گر تعداد پیکسل‌هایی است که مربوط به ترک است، اما به عنوان ترک تشخیص داده نشده‌اند (منفی کاذب). هدف نهایی در بهینه‌سازی پارامتر فراخوانی این است که هیچ پیکسلی از قسمت ترک به غلط به عنوان زمینه در نظر گرفته نشود و تأثیر زیادی در کاهش پیکسل‌های FP یا مثبت کاذب ندارد.

با توجه به این که دو پارامتر صحبت و فراخوانی، محدودیت هایی دارند که باعث می شود به تنها عملکرد مناسبی نداشته باشند؛ لذا پارامتر دقت F1-Score، که ترکیبی از دو پارامتر صحبت و فراخوانی است، به عنوان سومین پارامتر ارزیابی مدل، به این صورت تعریف می شود:

$$F \backslash = \frac{\gamma \times \Pr \times \text{Re}}{\Pr + \text{Re}} \quad (3)$$

تصویر

برچسب



شکل ۶. نمونه‌هایی از داده‌های موجود در مجموعه‌ی داده.

در فرایند یادگیری ماشین، معمولاً داده‌های موجود به دو دسته اختصاص می‌یابند: دسته‌ای اول، که برای آموزش استفاده می‌شود و دسته‌ی دوم، که برای ارزیابی نهایی مدل استفاده می‌شود. اما در مبحث یادگیری عمیق، موضوع کمی متفاوت است. به علت احتمال وقوع پیش برازش^{۲۹} در هنگام آموزش مدل، لازم است روشی اتخاذ شود که از عدم وقوع پدیده‌ی مذکور اطمینان حاصل شود. پیش برازش در مبحث یادگیری به حالتی اطلاق می‌شود که فرایند یادگیری بر روی داده‌ی آموزش بیش از اندازه انجام شود؛ در این حالت دقت پیش بینی مدل بر روی داده‌های آموزش بسیار بالاست، ولی برای پیش بینی داده‌های جدید مدل ناتوان است و عملکرد بسیار ضعیفی از خود نشان می‌دهد. به همین جهت لازم است روشی پیشنهاد شود که مدل را رصد و پیش از وقوع پیش برازش، از ادامه‌ی آموزش مدل جلوگیری کند. روش پیشنهادی برای غلبه بر چالش اخیر این بوده است که مجموعه‌ی داده‌ی استفاده شده به سه بخش آموزش^{۳۰}، اعتبارسنجی^{۳۱} و ارزیابی^{۳۲} تقسیم و آموزش طی دوره‌های^{۳۳} جداگانه انجام شود و در پایان، هر دوره‌ی اعتبارسنجی مدل با کمک داده‌های اعتبارسنجی انجام شود. بدین ترتیب در لحظه‌ی که مقدار هزینه^{۳۴} برای داده‌های اعتبارسنجی شروع به افزایش کند، لحظه‌ی شروع پیش برازش است. در فرایند آموزش مدل در پژوهش حاضر، مجموعه‌ی داده‌ی متشکل از ۴۵۸ تصویر، به سه قسمت تقسیم شده است: ۳۲۵ تصویر مختص آموزش، ۶۹ تصویر به منظور اعتبارسنجی و ۶۹ تصویر دیگر به منظور ارزیابی نهایی مدل استفاده شده‌اند.

۳.۲. پارامترها و معیارهای ارزیابی

در پژوهش حاضر با توجه به پیچیدگی داده‌ها و خروجی‌ها لازم بود پارامترهای دقیقی برای ارزیابی پیش‌بینی‌ها در نظر گرفته شوند. در داده‌های تصویری موجود در مجموعه‌ی داده‌ی استفاده شده در پژوهش حاضر، قسمت عمده‌ی تصاویر را پس زمینه‌ی آنها تشکیل داده و فقط درصدی بسیار جزئی (حدود ۰/۲۵٪) از پیکسل‌های هر تصویر متعلق به پیکسل‌های تک بوده است. در این حالت اگر یک معنای مطلق را سنجش می‌دانیم، نظر گفته شده، مسئله



شکل ۷. نتایج اعمال چند نمونه‌ی داده‌افزایی برای یک تصویر.

در مراجع مختلف بینایی رایانه، پارامتر دقت F1، به عنوان دقیق‌ترین پارامتر برای عملیات بخش‌بندی تصاویر در نظر گرفته می‌شود. پارامتر دقت F1، همچنین در تمامی مطالعات مربوط به بخش‌بندی تصاویر در حوزه‌ی شناسایی تک در بن، به عنوان پارامتر اصلی ارزیابی مدل‌ها استفاده می‌شود.

در پژوهش حاضر با توجه به پیشنهادشی^{۴۱} و همکاران (۲۰۱۶)،^{۱۸} پیکسل‌های TP با در نظر گرفتن دو پیکسل‌ای مرزی محسوسه شده‌اند. استدلال ارائه شده جهت چنین فرضی آن است که تک معمولاً دارای نواحی مرزی است و برچسب‌گذاری نواحی مرزی در برچسب‌گذاری دستی، دقت چندانی ندارد؛ لذا در نظر گرفتن ۲ تا ۵ پیکسل اضافه به عنوان پیکسل‌های TP امری رایج است. بنابر فرض اخیر در مطالعه‌ی حاضر، اگر یک پیکسل مثبت تشخیص داده شده و فاصله‌ی آن با پیکسل‌های تک، کمتر از دو پیکسل بوده است، به عنوان مثبت صحیح (TP) دسته‌بندی شده است. لازم به یادآوری است که مقدار اخیر در مطالعه‌ی شی و همکاران (۲۰۱۶)،^{۱۸} با توجه به کیفیت پایین تر برچسب‌گذاری دستی، مساوی ۵ پیکسل در نظر گرفته شده است.

۶.۲. آموزش مدل

همان‌گونه که در بخش ۲.۲.۲. اشاره شده است، آموزش و ارزیابی مدل در پژوهش حاضر بر روی یک مجموعه داده‌ی تصویری شامل ۴۵۸ تصویر انجام شده است، که ۳۲۰ تصویر برای فرایند آموزش، ۶۹ تصویر برای اعتبارسنجی، و ۶۹ تصویر برای ارزیابی نهایی مدل استفاده شده است. در ضمن مدل‌های یادگیری عمیق برای آموزش نیاز به تعداد بسیار بیشتری از داده‌ها دارند، لذا به عنوان یک راه حل رایج اقدام به داده‌افزایی^{۴۲} در قسمت استفاده شده در آموزش مدل شده است. داده‌افزایی عبارت از استخراج داده‌های جدید با استفاده از داده‌های موجود است. در داده‌های تصویری، رایج‌ترین روش‌های داده‌افزایی عبارت‌اند از: دوران، تغییر روشنایی، وارونه‌سازی، تغییر کانتراست و غیره. به کمک داده‌افزایی می‌توان احتمال بروز بیش‌برازش را به میزان کمینه رساند.

در مطالعه‌ی حاضر، از ۶ روش داده‌افزایی استفاده شده است، که به ترتیب عبارت‌اند از: وارونگی تصاویر در راستاهای عمودی و افقی، دوران تصادفی تصویر، انتقال چشم‌انداز^{۴۳}، اعمال نوفه‌ی گوسی^{۴۴}، تغییر تصادفی روشنایی^{۴۵} و تغییر تصادفی کانتراست.^{۴۶} هر یک از تغییرات مذکور چنانچه لازم باشد، برای برچسب‌ها نیز اعمال می‌شوند. در شکل ۷، نمونه‌هایی از نتایج حاصل از داده‌افزایی مشاهده می‌شود.

مهم‌ترین نکته در روش‌های داده‌افزایی این است که بدون آن که محتوای جدیدی تولید شود، داده‌های موجود به شکلی افزایش می‌یابند که بیشترین دقت ممکن در مدل حاصل می‌شود، بدون این که بیش‌برازش رخ دهد؛ همچنین در حالتی که تعداد داده‌ها کم باشد، مدل به سرعت دچار بیش‌برازش می‌شود.

در آموزش مدل پژوهش حاضر از یادگیری انتقالی، که یکی از روش‌های بسیار پرکاربرد در یادگیری ماشین و یادگیری عمیق است، استفاده شده است. بدین ترتیب که قسمت رمزگذار مدل ResNet ۱۰۱، دارای مقادیر وزن اولیه‌ی حاصل از آموزش قبلی بر روی مجموعه‌ی داده‌ی ImageNet هستند، که نقطه‌ی شروع بسیار خوبی برای مدل است. بدین ترتیب فرایند آموزش بسیار کوتاه‌تر از حالت معمول است و همچنین دقت مدل نیز بیشتر از سایر حالت‌های است و احتمال بیش‌برازش نیز کمتر است.

پژوهش حاضر، با استفاده از زبان برنامه‌نویسی پایتون^{۴۹} و با بهره‌گیری از کتابخانه‌ی Tensorflow^{۵۰}، که توسط تیم توسعه‌ی هوش مصنوعی گوگل^{۵۱} راهه شده است، به انجام رسیده است. جهت افزایش سرعت آموزش مدل

تابع هزینه، یکی از مهم‌ترین ارکان فرایند یادگیری ماشین و یادگیری عمیق است. در بسیاری از مراجع پیشین، یادگیری ماشین به صورت یک مسئله‌ی بهینه‌سازی قابل تعریف است، که هدف آن رسیدن به مقدار کمینه‌ی هزینه است. در نتیجه بسیار مهم است که برای حل یک مسئله از چه تابع هزینه‌یی استفاده شود و میزان تناسب تابع هزینه با پارامترهای مورد نظر در حل مسئله، تأثیر مستقیمی در عملکرد نهایی مدل دارد.

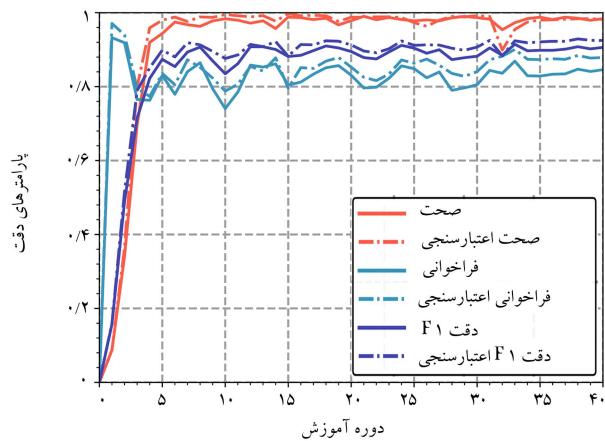
با توجه به این که هدف در مطالعه‌ی حاضر رسیدن به بیشترین دقت F1-Score بوده است، لازم بود تابع هزینه‌یی تعریف شود که بیشترین تناسب را با پارامتر F1Score داشته باشد. خوشبختانه تابع هزینه‌یی با عنوان دایس^{۴۲}،^{۱۹} مستقیماً مقدار F1 را بهینه می‌سازد رابطه‌ی^{۴۳}:

$$Dice_Loss = \frac{1}{N} \sum_1^N 1 - \frac{2|\hat{y} \cap y|}{|\hat{y}| + |y|} \quad (4)$$

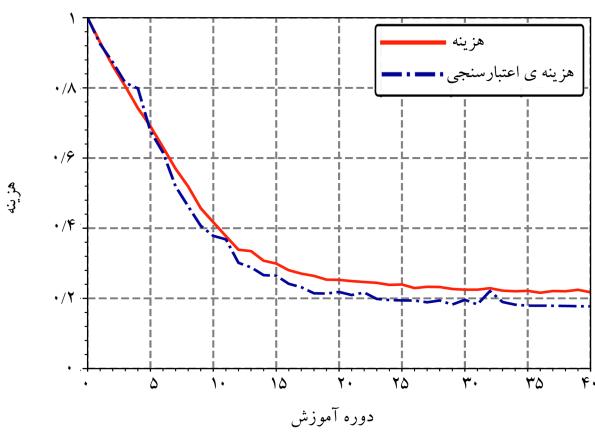
که در آن، \hat{y} و y به ترتیب بیان‌گر برچسب حقیقی و برچسب پیش‌بینی شده هستند. همچنین N تعداد کلاس موجود در مسئله است.

۵. بهینه‌ساز

در مبحث یادگیری عمیق، الگوریتم‌های بسیاری جهت بهینه‌سازی توابع هزینه معرفی شده‌اند، که هر یک برای دسته‌ی از مسائل، می‌تواند مناسب باشد. در حوزه‌ی بینایی رایانه، دو الگوریتم کاهش تصادفی گرادیان (SGD)^{۴۳} و آدام (Adam) بهترین عملکردها را از آن خود کرده‌اند. هر دو مورد از الگوریتم‌های فوق بر اساس کاهش گرادیان عمل می‌کنند، با این تفاوت که آدام ترکیبی از دو زیرمجموعه‌ی اخیر گرادیان تصادفی RMSProp و AdaGrad است. ترکیب دو زیرمجموعه‌ی اخیر در الگوریتم آدام، اگرچه در مسائل بسیار دشوار، دقت کمتری نسبت به SGD ارائه می‌دهد، اما سرعت همگرایی بسیار بالای آن و همچنین مقاومت آن در برخورد با نویز، آن را به پرکاربردترین الگوریتم بهینه‌سازی در زمینه‌ی بینایی رایانه مبدل ساخته است. در پژوهش حاضر، از الگوریتم آدام با نزد یادگیری ۱۰۰۰۰ به عنوان الگوریتم بهینه‌ساز استفاده شده است.



شکل ۹. نمودار تغییرات پارامترهای ارزیابی در طول آموزش.



شکل ۸. نمودار تغییرات هزینه در طول آموزش مدل.

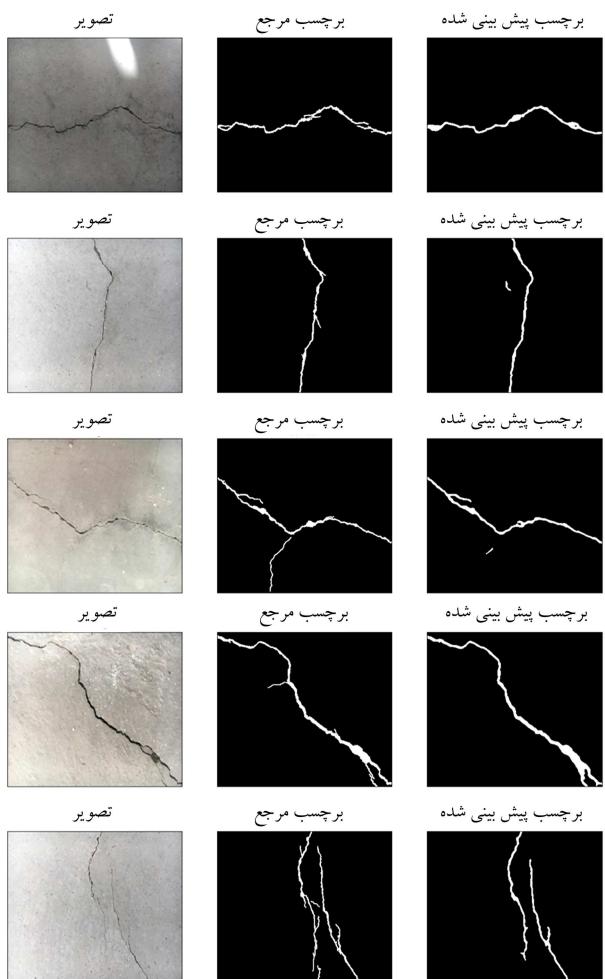
ResNet ۱۰۱، به جای واحد پردازندهی مرکزی (CPU) ^{۵۱}، از یک پردازندهی گرافیکی (GPU) ^{۵۲}، مدل ۸۰ NVIDIA TESLA-K استفاده شده است، که در بستر CUDA ^{۵۳} با زبان برنامه‌نویسی باقیون مرتبه بوده و سرعت پردازشی دهها برابر پردازندههای CPU داشته است. آموزش مدل در ۴۰ دوره انجام پذیرفته و در پایان هر دورهی عملیات اعتبارسنجی، وضعیت برازش مدل بررسی شده است.

٣. نتایج و بحث

پس از تکمیل مدل و معرفی تمامی پارامترهای معرفی شده در بخش ۲، آموزش مدل شروع شده است. هر دوره از آموزش مدل حدود ۵۳ ثانیه زمان می‌برد، که در مجموع تمامی ۴۰ دوره، حدود ۳۵ دقیقه زمان لازم است تا فرایند یادگیری تکمیل شود. تغییرات مقادیر هزینه و پارامترهای ارزیابی مدل در طول فرایند آموزش در جدول ۲ آرائه شده است، که در آن، مقادیر مربوط به دقت F1 که پارامتر اصلی دقت مطالعه‌ی حاضر است، با رنگ خاکستری مشخص شده است.

در جدول ۲ مشاهده می شود که با گذشت مراحل آموزش مدل، مقادیر هزینه، کاهش و متقابلاً مقادیر دقت، افزایش یافته است. در مراحل پایانی نیز مدل به حالتی ثابت دست یافته و تغییرات با کندی مواجه شده است. لازم به ذکر است که در صورت ادامه‌ی روند آموزش، احتمال وقوع بیش برآش وجود دارد، که در این حالت مقادیر هزینه و دقت برای داده‌های آموزش با شبیه تدریجی پیشین به پیشرفت خود ادامه می‌دهند، اما عملکرد مدل برای داده‌ی اعتبارسنجی با افت شدید روبه رو می شود، که بدین معناست عملکرد مدل برای داده‌های جدید با اختلال مواجه شده است. لذا لازم است که از ادامه‌ی پیشتر روند آموزش چلکوگری به عمل آید.

همچنین در شکل های ۸ و ۹ نمودارهای تغییرات هزینه و پارامترهای ارزیابی در طول فرایند آموزش مشاهده می شوند. توضیحات اخیر درباره نمودارهای مذکور نیز صدق می کند و همان طور که مشاهده می شود، مقادیر هزینه و پارامترهای ارزیابی برای داده های آموزش و اعتیارسنجی به موازات هم پیشرفت کرده و در مراحل پایانی آموزش به ثبات رسیده اند. گفتنی است که در صورت وقوع پدیده هی بیش برآزانش، نمودارهای مربوط به داده ای اعتیارسنجی چهار آفت ناگهانی می شود؛ که بدان معناست که با وجود افزایش دقت برای داده ای آموزش، عملکرد مدل برای داده های جدید ضعیف تر شده است. با توجه به این که چنین اتفاقی در نمودارهای شکل های ۸



شکل ۱۵. نمونه‌هایی از پیش‌بینی مدل برای داده‌های ارزیابی (تصویر سمت راست) به همراه جزئیات اصلی (تصویر وسط).

جدول ۲. جزئیات پارامترهای مدل در طی آموزش.

F ₁ دقت اعتبارسنجی	فراخوانی اعتبارسنجی	صحت اعتبارسنجی	هزینه‌ی اعتبارسنجی	F ₁	فراخوانی	صحت	هزینه	گام
۰/۱۵۹۴۷۲	۰/۹۷۰۸۳۰	۰/۰۸۷۶۱۰	۰/۹۲۵۰۱۴	۰/۱۵۷۴۸۷	۰/۹۳۲۴۷۴	۰/۰۸۷۰۷۹	۰/۹۲۹۵۲۷	۱
۰/۱۶۳۸۳	۰/۹۳۹۹۱۵	۰/۳۶۴۶۵۸	۰/۱۸۷۳۱۱۳	۰/۴۸۹۶۰۶	۰/۹۱۸۸۲۳	۰/۳۴۱۱۴۳	۰/۰/۸۶۳۱۳۵	۲
۰/۷۸۹۴۰۵	۰/۷۹۵۴۲۹	۰/۷۹۹۵۸۴	۰/۱۸۱۴۸۳۰	۰/۷۱۴۳۹۱	۰/۷۶۵۴۱۴	۰/۸۹۶۲۲۹	۰/۸۰۴۴۹۷	۳
۰/۸۵۰۹۱۲	۰/۷۷۳۶۴۶	۰/۹۵۹۰۸۵	۰/۷۹۸۵۲۹	۰/۸۲۲۴۱۴	۰/۷۶۳۰۹۲	۰/۹۱۹۷۵۰	۰/۷۴۲۳۲۹	۴
۰/۱۹۸۷۲۰	۰/۸۳۵۶۲۲	۰/۹۷۹۸۶۳	۰/۶۷۶۴۲۴	۰/۸۷۳۸۰۱	۰/۸۳۰۴۳۸	۰/۹۴۳۹۴۷	۰/۸۹۰۴۲۳	۵
۰/۱۸۰۵۳۸	۰/۸۰۵۲۴۳	۰/۹۸۸۱۱۳۷	۰/۶۱۵۶۰۸	۰/۸۰۴۲۵۱	۰/۷۷۹۳۲۴	۰/۹۷۴۶۸۵	۰/۶۳۰۵۶۸	۶
۰/۹۱۹۰۷۴	۰/۸۷۷۲۷۳۸	۰/۹۷۶۲۲۲	۰/۱۵۱۹۲۰۴	۰/۸۹۳۵۹۲	۰/۸۴۰۴۹۶	۰/۹۶۷۵۸۴	۰/۶۶۹۴۰۴	۷
۰/۹۱۳۰۸۹	۰/۸۵۲۲۷۴	۰/۹۸۸۶۶۴	۰/۴۶۲۲۹۹	۰/۹۰۶۹۵۸	۰/۸۶۴۶۶۱	۰/۹۶۳۰۸۷	۰/۵۱۸۸۴۷	۸
۰/۱۹۵۳۸۷	۰/۸۲۳۱۱۷۳	۰/۹۸۷۳۷۶	۰/۴۰۶۷۸۰	۰/۸۶۹۵۷۷	۰/۷۹۴۴۳۴	۰/۹۷۷۸۶۰	۰/۴۵۶۹۲۳	۹
۰/۸۷۸۲۱	۰/۷۸۸۰۵۸	۰/۹۹۵۰۲۹۷	۰/۳۷۸۲۴۸	۰/۸۳۴۹۴۱	۰/۷۴۰۶۰۹	۰/۹۸۳۶۳۶	۰/۴۱۶۹۰۵	۱۰
۰/۱۸۸۵۹۰۱	۰/۸۰۶۴۰۳	۰/۹۹۱۷۷۳	۰/۳۶۸۲۸۶	۰/۸۶۲۱۱۷	۰/۷۸۸۴۹۶	۰/۹۷۹۷۶۸	۰/۳۷۷۴۷۴	۱۱
۰/۹۱۴۳۲۵	۰/۸۰۴۸۶۴	۰/۹۸۸۷۱۴	۰/۳۰۱۳۶۱	۰/۹۰۸۰۴۲	۰/۸۰۸۲۰۱	۰/۹۷۱۷۳۹	۰/۳۳۸۷۳۰	۱۲
۰/۹۰۸۸۳۶	۰/۸۴۲۱۰۲	۰/۹۹۲۰۹۸	۰/۲۸۸۵۰	۰/۹۰۷۸۳۰	۰/۸۵۲۹۸۳	۰/۹۷۸۱۰۲	۰/۳۳۴۸۳۸	۱۳
۰/۹۲۲۰۱۲	۰/۸۷۷۹۰۷	۰/۹۷۷۱۲۵	۰/۲۶۶۲۵۷	۰/۹۰۰۵۸۳	۰/۸۶۱۶۴۸	۰/۹۵۲۲۱۷	۰/۳۰۷۴۵۶	۱۴
۰/۸۸۲۶۷۶	۰/۷۹۶۱۸۲	۰/۹۹۷۷۱۱	۰/۲۶۴۸۹۵	۰/۸۸۱۶۰۷	۰/۸۰۴۱۷۵	۰/۹۸۸۳۱۷	۰/۹۹۲۶۹۴	۱۵
۰/۹۱۳۹۱۲	۰/۸۵۱۴۲۷	۰/۹۹۱۶۵۱	۰/۲۴۱۶۰۵	۰/۸۸۴۷۳۷	۰/۸۱۲۳۷۶	۰/۹۸۶۴۶۲	۰/۲۸۰۳۱۱	۱۶
۰/۹۱۳۱۶۳	۰/۸۴۹۳۲۶	۰/۹۹۳۱۹۱	۰/۲۳۱۸۴۲	۰/۸۹۷۳۹۵	۰/۸۳۳۷۴۶	۰/۹۸۱۴۹۸	۰/۲۷۰۶۳۱	۱۷
۰/۹۲۴۰۲۲	۰/۸۶۸۹۶۴	۰/۹۹۱۶۸۰	۰/۲۱۴۶۴۶	۰/۹۱۰۰۶۲	۰/۸۰۱۱۷۶	۰/۹۸۰۵۲۹۱	۰/۲۶۴۲۲۲	۱۸
۰/۹۲۲۸۱۱	۰/۸۷۸۹۴۰	۰/۹۷۶۰۱۶	۰/۲۱۳۸۸۵	۰/۹۰۴۷۰۳	۰/۸۰۶۹۰۹	۰/۹۶۷۰۷۷	۰/۲۵۳۴۱۳	۱۹
۰/۹۱۲۸۱۲	۰/۸۵۲۶۹۶	۰/۹۸۷۶۶۲	۰/۲۱۸۳۴۰	۰/۸۹۰۰۲۴	۰/۸۳۱۰۳۷	۰/۹۷۸۴۲۳	۰/۲۵۲۸۲۵	۲۰
۰/۸۹۶۳۶	۰/۸۲۵۴۰۱	۰/۹۸۷۸۸۶	۰/۲۰۹۶۱۷	۰/۸۷۸۶۹۵	۰/۷۹۶۴۲۹	۰/۹۹۰۳۰۹	۰/۲۴۹۲۵۶	۲۱
۰/۸۹۱۶۲۱	۰/۸۱۶۲۷۶	۰/۹۸۸۹۰۶	۰/۲۱۶۷۲۱	۰/۸۷۴۸۸۱	۰/۷۹۸۳۲۷	۰/۹۸۱۰۷۴	۰/۲۴۶۷۹۳	۲۲
۰/۹۰۲۴۲۱	۰/۸۳۳۹۸۱	۰/۹۸۸۹۳۴	۰/۱۹۸۴۹۴	۰/۸۹۳۷۱۴	۰/۸۲۲۷۱۳	۰/۹۸۷۱۰۸	۰/۲۴۴۳۳۷	۲۳
۰/۹۲۳۴۳۸	۰/۸۷۲۱۱۲	۰/۹۸۶۶۸۸	۰/۱۹۵۳۸۳	۰/۹۱۱۶۹۰	۰/۸۰۶۲۰۱	۰/۹۸۱۰۲۳	۰/۲۳۸۶۰۵	۲۴
۰/۹۱۱۸۴۲	۰/۸۶۳۰۰۳	۰/۹۷۳۱۸۸	۰/۱۹۴۲۲۴	۰/۹۰۴۲۵۷	۰/۸۴۸۰۸۴	۰/۹۷۸۲۸۷	۰/۲۳۹۷۵۰	۲۵
۰/۹۱۳۱۶۸	۰/۸۷۴۵۲۲	۰/۹۶۳۱۸۲	۰/۱۹۳۹۱۵	۰/۸۹۰۰۳۹۱	۰/۸۲۴۰۸۸	۰/۹۰۸۶۰۳	۰/۲۲۹۴۰۲	۲۶
۰/۹۱۲۴۸	۰/۸۵۷۸۱۲	۰/۹۷۹۹۷۷	۰/۱۸۸۸۷۶	۰/۸۹۹۸۸۲	۰/۸۳۹۵۸۸	۰/۹۷۷۹۲۸	۰/۲۳۳۱۴۴	۲۷
۰/۹۰۳۹۰۵	۰/۸۳۵۸۳۸	۰/۹۸۹۷۶۵	۰/۱۹۳۹۹۸	۰/۸۷۳۲۲۳	۰/۷۹۰۱۹۰	۰/۹۸۶۴۲۱	۰/۲۳۲۵۰۷	۲۸
۰/۸۹۸۳۴	۰/۸۲۷۸۴۲	۰/۹۸۸۰۵۴	۰/۱۸۲۰۵۲	۰/۸۷۸۲۳۱	۰/۷۹۶۷۴۹	۰/۹۹۰۱۰۷	۰/۲۲۶۹۲۷	۲۹
۰/۹۰۷۰۳۶	۰/۸۴۰۵۹۳	۰/۹۹۱۶۵۷	۰/۱۹۰۹۱۸	۰/۸۸۲۲۶۴	۰/۸۰۰۱۷	۰/۹۸۶۰۰۶	۰/۲۲۴۹۰۵	۳۰
۰/۹۲۵۱۱۵	۰/۸۷۷۲۶۱	۰/۹۸۹۷۰۸	۰/۱۸۷۷۷۷	۰/۹۰۴۸۶۹	۰/۸۴۳۹۸۱	۰/۹۸۲۶۲۳	۰/۲۲۴۸۸۹	۳۱
۰/۸۸۳۵۱۵	۰/۸۸۲۴۳۳	۰/۸۹۹۰۶۱	۰/۲۲۱۰۳۴	۰/۸۸۴۹۲۹	۰/۸۳۶۴۲۴	۰/۹۵۳۸۹۵	۰/۲۲۹۱۲۲	۳۲
۰/۹۲۳۹۴۳	۰/۹۰۰۶۹۴	۰/۹۵۴۸۰۳	۰/۱۸۷۷۵۲	۰/۹۱۴۷۶۶	۰/۸۶۸۹۴۱	۰/۹۷۳۰۳۱	۰/۲۲۲۱۱۳	۳۳
۰/۹۱۸۸۲۴	۰/۸۷۴۰۵۸	۰/۹۷۴۷۸۰	۰/۱۸۲۱۱۶	۰/۸۹۶۸۱۸	۰/۸۲۹۵۱	۰/۹۸۴۰۷۵	۰/۲۲۰۲۷۰	۳۴
۰/۹۲۱	۰/۸۷۳۲۶۲	۰/۹۸۰۱۱۴	۰/۱۷۹۳۹۲	۰/۸۹۸۲۴۵	۰/۸۲۸۶۸۹	۰/۹۸۷۸۸۸	۰/۲۲۱۶۱۸	۳۵
۰/۹۲۲۷۷۲	۰/۸۷۸۰۶۰	۰/۹۸۰۹۱۹	۰/۱۷۹۳۰۸	۰/۸۹۸۲۰۱	۰/۸۳۳۵۷۷	۰/۹۸۱۰۳۶	۰/۲۱۶۰۷۷	۳۶
۰/۹۲۲۵۱۵	۰/۸۷۳۸۸۲	۰/۹۸۲۳۸۳	۰/۱۷۹۰۸۴	۰/۹۰۱۳۵۸	۰/۸۲۴۵۰۹	۰/۹۸۷۸۶۱	۰/۲۲۱۰۰۹	۳۷
۰/۹۲۹۱۱۵	۰/۸۸۴۴۴	۰/۹۸۳۶۳۹	۰/۱۷۸۵۳۵	۰/۹۰۸۰۳۷	۰/۸۴۷۷۸۶	۰/۹۸۰۰۳۴	۰/۲۲۰۲۶۴	۳۸
۰/۹۲۵۳۵۵	۰/۸۷۷۳۷۳	۰/۹۸۴۱۸۰	۰/۱۷۷۸۰۷	۰/۹۰۲۲۲۰	۰/۸۴۱۰۴۵	۰/۹۷۹۶۰۳	۰/۲۲۴۵۶۲	۳۹
۰/۹۲۴۷۸۷	۰/۸۷۸۸۷۸	۰/۹۸۱۳۲۸	۰/۱۷۷۰۹۶	۰/۹۰۶۱۷۱	۰/۸۴۵۸۰۵	۰/۹۸۳۸۹۴	۰/۲۱۷۵۱۲	۴۰

عصبی کانولوشن پرکاربرد و معروف ResNet^{۱۰۱} و در قسمت رمزگشای نیز از پنج لایه‌ی بازگرداننده استفاده شده است، تا ابعاد داده‌ی رمزگذاری شده را به مقدار اولیه‌ی دلخواه برسانند. مدل مذکور بر روی یک مجموعه داده‌ی برچسب‌گذاری شده شامل ۴۵۸ تصویر از سطوح ترک خورده‌ی بتن آموزش دیده است، که در فرایند آموزش آن از انواع روش‌های داده‌افزایی و همچنین از یادگیری انتقالی استفاده شده است، تا نتیجه‌ی بهینه حاصل شود. در نهایت دقت ارزیابی ۳۸/۹۱٪، بیان‌گر قدرت بسیار بالای مدل مذکور در تشخیص ترک در سطوح بتنی است.

البته دقت به این موضوع ضروری است که اگر چه مجموعه داده‌ی استفاده شده در پژوهش حاضر، مجموعه‌ی کامل و دقیق و در برگیرنده‌ی انواع مختلف ترک‌ها بوده است، اما زمینه‌ی تصاویر اغلب ساده و بدون حضور اجسام خارجی بوده است، در نتیجه باید انتظار مقداری خطأ در عملکرد مدل مذکور در مواجهه با زمینه‌های پیچیده‌تر را داشت. همچنین به عنوان مسیری برای مطالعات پیش روی رفع و رجوع آن کرد.

علاوه بر این، تمرکز پژوهش حاضر بر روی رسیدن روشی بهینه در بخش‌بندی تصاویر ترک در بتن بوده است، که این روش قادر است بیشترین جزئیات مربوط به ترک را در مقیاس پیکسل گزارش کند. با توجه به این‌که جزئیاتی، همچون: نوع ترک، ابعاد و محل قرارگیری آن در مبحث پایش سلامت سازه‌ها، اهمیت ویژه‌ی دارد، می‌توان روش ارائه شده در پژوهش حاضر را توسعه داد و در مطالعات پیش رو، جزئیات مورد نظر را در قالب یک مثال عملی برای یک نمونه‌ی بتنی استخراج کرد. برای این منظور می‌توان از دوربین‌های چندگانه که قادر به محاسبه‌ی ابعاد هستند، استفاده و ابعاد را استخراج کرد. همچنین از بعد نرم‌افزاری می‌توان مدل‌های جانی یادگیری ماشین را تعریف کرد، که برخی ویژگی‌ها، که به کمک ابعاد قابل استخراج نیستند، را نیز به دست آورد.

جدول ۳. پارامترهای نهایی پیش‌بینی مدل برای داده‌ی ارزشیابی.

پارامتر	مقدار
صحبت	۰/۹۹۳۹
فراخوانی	۰/۸۴۹۹
دقت	F1 ۰/۹۱۳۸

در روش یادگیری انتقالی استفاده شده در پژوهش حاضر جستجو کرد؛ که در آن، قسمت رمزگذار مدل، که یک شبکه‌ی عصبی کانولوشنال است، به صورت از پیش آموزش دیده در مدل قرار گرفته و لذا نیازی به آموزش مجدد آن نبوده است. در مطالعه‌ی حاضر، فقط قسمت رمزگذار مدل، آموزش داده شده است، که این موضوع علاوه بر افزایش دقت، به طرز چشمگیری سرعت آموزش مدل را نیز افزایش داده است.

مقادیر دقت نهایی برای داده‌ی ارزیابی در جدول ۳ ارائه شده است. همچنین زمان لازم جهت انجام پیش‌بینی برای داده‌ای جدید حدود ۲۰ ثانیه است. در شکل ۱۰، چند نمونه از نتایج خروجی مدل به همراه برچسب اصلی مشاهده می‌شود.

۴. نتیجه‌گیری

در پژوهش حاضر، با هدف اتوماسیون مبحث بازرسی بصری در حوزه‌ی پایش سلامت سازه‌ها و با بهره‌گیری از مبحث یادگیری عمیق و شبکه‌های عصبی کانولوشنال و کاربرد آنها در حوزه‌ی بیانی رایانه اقدام به شناسایی ترک در اعضاء بتنی شده است. نوع شبکه‌ی استفاده شده در پژوهش حاضر، یک شبکه‌ی رمزگذار، رمزگشای Encoder-Decoder (Encoder-Decoder) بوده است، که با برقراری ارتباط میان عنصر رمزگذار و رمزگشای به حالت بهینه‌ی خود می‌رسد. در قسمت رمزگذار مدل مذکور از شبکه‌ی

پانوشت‌ها

1. structural health monitoring
2. piezoelectric
3. fiber optic
4. deep learning
5. edge detectors
6. convolutional neural networks
7. Cha
8. classification
9. region-based convolutional neural network
10. Gopalakrishnan
11. transfer learning
12. Dung
13. fully convolutional neural network
14. semantic segmentation
15. binary image
16. encoder - decoder
17. Liu
18. optimizer
19. pooling
20. object detection
21. semantic segmentation
22. decoder
23. encoder-decoder
24. feature extraction
25. classifier
26. Sigmoid
27. middle east technical university
28. Zhang
29. overfitting
30. train
31. alidation
32. test
33. epochs
34. loss
35. precision
36. recall
37. F1-score
38. true positive
39. false positive
40. false negative
41. Shi
42. Dice Loss
43. stochastic gradient descent
44. data augmentation
45. perspective transform

46. gaussian noise
47. random brightness
48. random contrast
49. Python
50. Google brain team
51. central processing unit
52. graphics processing unit
53. compute unified device architecture

منابع (References)

1. Aboudi, J. "Stiffness reduction of cracked solids", *Engineering Fracture Mechanics*, **26**(5), pp. 637-650 (1987).
2. Huang, T., Chang, C. and Yang, Z. "Elastic moduli for fractured rock mass", *Rock Mechanics and Rock Engineering*, **28**(3), pp. 135-144 (1995).
3. Abdel-Qader, I., Abudayyeh, O. and Kelly, M.E. "Analysis of edge-detection techniques for crack identification in bridges", *Journal of Computing in Civil Engineering*, **17**(4), pp. 255-263 (2003).
4. Sinha, S.K. and Fieguth, P.W. "Automated detection of cracks in buried concrete pipe images", *Automation in Construction*, **15**(1), pp. 58-72 (2006).
5. Metni, N. and Hamel, T. "A UAV for bridge inspection: visual servoing control law with orientation limits", *Automation in Construction*, **17**(1), pp. 3-10 (2007).
6. Adhikari, R., Moselhi, O. and Bagchi, A. "Image-based retrieval of concrete crack properties for bridge inspection", *Automation in Construction*, **39**, pp. 180-194 (2014).
7. Cha, Y.J., Choi, W. and Büyüköztürk, O. "Deep learning-based crack damage detection using convolutional neural networks", *Computer-Aided Civil and Infrastructure Engineering*, **32**(5), pp. 361-378 (2017).
8. Cha, Y.J., Choi, W., Suh, G. and et al. "Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types", *Computer-Aided Civil and Infrastructure Engineering*, **33**(9), pp. 731-747 (2018).
9. Gopalakrishnan, K., Khaitan, S.K., Choudhary, A. and et al. "Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection", *Construction and Building Materials*, **157**, pp. 322-330 (2017).
10. Simonyan, K. and Zisserman, A. "Very deep convolutional networks for large-scale image recognition", *ArXiv Preprint ArXiv*, **1409**, 1556v6 (2014).
11. Deng, J., Dong, W., Socher, R. and et al. "Imagenet: A large-scale hierarchical image database", In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248-255 (2009).
12. Dung, C.V. "Autonomous concrete crack detection using deep fully convolutional neural network", *Automation in Construction*, **99**, pp. 52-58 (2019).
13. Ronneberger, O., Fischer, P. and Brox, T. "U-net: convolutional networks for biomedical image segmentation", In: *International Conference on Medical image computing and computer-assisted intervention*, Springer, pp. 234-241 (2015).
14. Liu, Z., Cao, Y., Wang, Y. and et al. "Computer vision-based concrete crack detection using U-net fully convolutional networks", *Automation In Construction*, **104**, pp. 129-139 (2019).
15. He, K., Zhang, X., Ren, S. and et al. "Deep residual learning for image recognition", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778 (2016).
16. Özgenel, Çağlar, FLrat. "Concrete crack segmentation dataset", In: *Mendeley Data* (Ed.), V1 (2019). DOI:10.17632/jwsn7tfbrp.1.
17. Zhang, L., Yang, F., Zhang, Y.D. and et al. "Road crack detection using deep convolutional neural network", In: *2016 IEEE International Conference on Image Processing (ICIP)*, pp. 3708-3712 (2016).
18. Shi, Y., Cui, L., Qi, Z. and et al. "Automatic road crack detection using random structured forests", *IEEE Transactions on Intelligent Transportation Systems*, **17**(12), pp. 3434-3445 (2016).
19. Milletari, F., Navab, N. and Ahmadi, S.-A. "V-net: fully convolutional neural networks for volumetric medical image segmentation", In: *2016 Fourth International Conference on 3D Vision (3DV)*, IEEE, pp. 565-571 (2016).
20. Abadi, M., Agarwal, A., Barham, P. and et al. "TensorFlow: large-scale machine learning on heterogeneous systems", *ArXiv Preprint*, **1603**, 04467 (2016).
21. NVIDIA Developer, Vingelmann, P. and Fitzek, Frank H.P. "CUDA Toolkit", Available at: <https://developer.nvidia.com/cuda-toolkit> (2020).