

تشخیص ترک در سازه‌های بتنی با کاربرد شبکه عصبی کانولوشن

مهران سیف‌الهی^۱، سلیم عباسی^۲، مازیار فهیمی فرزام^{۳*}، رسول دانشفراز^۴

- ۱- کارشناسی ارشد عمران-سازه‌های هیدرولیکی، دانشگاه تبریز
- ۲- کارشناسی ارشد عمران-سازه‌های هیدرولیکی، دانشگاه محقق اردبیلی
- ۳- دانشیار بخش مهندسی عمران-سازه، دانشگاه مراغه
- ۴- استاد بخش مهندسی عمران-سازه‌های هیدرولیکی، دانشگاه مراغه

Email: M.farzam@maragheh.ac.ir*

تاریخ پذیرش: ۱۴۰۰/۱۲/۱۵

تاریخ دریافت: ۱۴۰۰/۰۲/۰۵

چکیده

یکی از زمینه‌های فعال تحقیقاتی در بحث پایش سلامت سازه‌های بتنی تشخیص رخداد ترک در المان‌های سازه‌ای است. طبقه‌بندی و تشخیص فنی براساس تصویر، روشی است که امروزه مورد توجه بسیاری از پژوهشگران قرار گرفته است. انجام روش مبتنی بر تصویر به دلیل پیشرفت فناوری تصویربرداری و پردازش سریع آن‌ها به سهولت صورت می‌گیرد، که این تشخیص توسط شبکه عصبی کانولوشن (CNN) انجام می‌شود. در این تحقیق تشخیص ترک در سازه‌های بتنی با استفاده از شبکه عصبی کانولوشنی مطالعه شده است. مطالعه حاضر قابل تعمیم به تمام سازه‌های بتنی برای نمونه سد، کانال، پل‌ها، پوسته‌ها، زیرسازهای راه‌ها و اسکلت‌های بتنی می‌باشد. بانک اطلاعاتی این پژوهش شامل ۴۰,۰۰۰ تصویر که، ۲۰,۰۰۰ تصویر بتن ترک‌خورده و ۲۰,۰۰۰ بتن ترک‌نخورده با ابعاد $۲۲۷ \times ۲۲۷ \times ۳$ پیکسل می‌باشد، ۸۰ درصد تصاویر برای آموزش و ۲۰ درصد باقیمانده برای راستی‌آزمایی روش شبکه عصبی کانولوشن استفاده می‌شوند. دقت تشخیص بتن ترک‌خورده از ترک‌نخورده در حدود $۹۸/۱۶$ درصد می‌باشد، که برای عملیاتی شدن قابل قبول است و کاربردی محسوب می‌شود. همچنین طبق تحلیل ماتریس درهم‌ریختگی تعداد ۱۴۷ تصویر از ۸,۰۰۰ تصویر داده‌های راستی‌آزمایی به صورت اشتباه دسته‌بندی شده‌اند.

واژگان کلیدی: ترک در بتن، شبکه عصبی کانولوشن، پایش سلامت سازه، واحد پردازش گرافیکی

۱- مقدمه

می‌گذرد و برای نگهداری و بهره‌برداری نیاز به بازدید دوره‌ای و دقیق دارند [1]. تجزیه و تحلیل آماری از پل‌های تخریبی بازرسی شده نشان می‌دهد، حدود ۴۵ درصد این پل‌ها قبل از خرابی دارای ترک بوده و قبل از تخریب، از خود علائم

سازه‌های زیربنایی مانند پل‌ها، جاده‌ها، سدها و کانال‌های انتقال آب بارگذاری‌های متفاوتی را در طول عمر خود تجربه می‌کنند و تحت تاثیر آن‌ها فرسوده و تخریب می‌شوند. به عنوان نمونه بیشتر پل‌ها در ایالات متحده بیش از ۵۰ سال از عمرشان

این فرآیند، تحلیل تصویر توسط ماشین برای تخمین بار حداکثری قابل تحمل توسط تیر و دال، براساس ترک‌های ایجاد شده در بتن نیز استفاده شد [14]. به تازگی چندین تحقیق در مورد تشخیص خودکار ترک در بتن، سطح راه‌ها و نیروگاه‌های هسته‌ای نیز توسعه یافته است [15, 16].

یکی از اهداف اساسی الگوریتم‌های یادگیری ماشین، شمول یادگیری‌ها به فراتر از نمونه‌های آموزش داده شده است، یعنی تفسیر موفقیت آمیز داده‌ها [9]. به طوری که در سطوح مختلف نمایش یا انتزاع، یادگیری را برای ماشین انجام می‌دهد. با این کار، ماشین درک بهتری از واقعیت وجودی داده‌ها پیدا کرده و می‌تواند الگوهای مختلف را شناسایی کند. برای شناسایی یادگیری عمیق، ابتدا نیاز به دانستن شبکه‌های عصبی می‌باشد. براساس تعریف مشهور، یادگیری عمیق در واقع همان یادگیری به وسیله شبکه‌های عصبی هستند که دارای لایه‌های پنهانی زیادی می‌باشند. هر چقدر در لایه‌های یک شبکه عصبی عمیق جلوتر می‌رویم، به مدل‌های پیچیده‌تر و کامل‌تری می‌رسیم [16].

یادگیری عمیق یکی از عناصر مهم در علم داده می‌باشد که شامل آمار و مدل‌سازی به منظور پیش‌بینی است. یادگیری عمیق مطابق شکل (۱) برای پژوهشگران علم داده که وظیفه جمع-آوری، تجزیه و تحلیل و تفسیر مقادیر زیادی از داده‌ها را دارند، بسیار مفید است و این روند را سریع‌تر و آسان‌تر می‌کند. در حالی که یادگیری ماشین سنتی به صورت خطی است [15].

شبکه عصبی کانولوشن بر مبنای بازدیدهای انجام داده شده، عمل می‌کند. یک بازدیدکننده آموزش دیده براساس محل و عرض ترک، شدت ترک ایجاد شده در عضو را ارزیابی می‌نماید، که این کار اگر به صورت دستی و با چشم غیر مسلح و یا مسلح صورت گیرد، زمان‌بر می‌باشد و همچنین خطا در تشخیص و ارزیابی محتمل است. تشخیص ترک با استفاده از تصاویر گرفته شده به وسیله تلفن‌های هوشمند و یا دوربین‌های عکاسی دارای چندین فرض است. فرض اول: ترک‌ها باریک و غیرمنقطع باشند. فرض دوم: خطوط ترک تیره‌تر و تاریک‌تر از محیط اطراف باشند [17].

شکست بروز داده‌اند [2]. تشخیص سریع و شناسایی آسیب-های ساختاری حاصل از ناهمگنی‌ها و تداخل، مسئله‌ای دشوار است. علاوه بر این، آزمایش‌های عملکرد لرزه‌ای به طور گسترده‌ای روی سازه‌های بتنی با استفاده از تصاویر و فیلم به روش پردازش تصویر انجام شده است [4]. از همین رو ضرورت و نیاز به یافتن راهکاری کارآمد و قابل اعتماد برای پایش سلامت سازه‌ها به صورت آنلاین و سریع به گونه‌ای که هر سازه زیربنایی به صورت دوره‌ای پایش و بررسی شود، ضروری به نظر می‌رسد.

برای تشخیص ترک در حالت کلی از دو روش فیزیکی و هوشمند استفاده می‌شود، بدین ترتیب که در روش فیزیکی بازدید چشمی، آزمایش مواد نافذ و امواج فراصوتی به کار برده می‌شود و در روش هوشمند با استفاده از پردازش تصویر به روش یادگیری عمیق روی تصاویر دیجیتال، لیزری و فرا صوت تشخیص ترک انجام می‌شود [5]. در روش‌های هوشمند برخلاف روش‌های فیزیکی تاثیر خطای انسانی و دستگاه‌های اندازه‌گیری وجود نداشته، علاوه بر آن تکنیک‌های روش‌های هوشمند، تشخیص ترک را تا حدودی خودکار می‌کند. اما تاثیر خلل و فرج، رنگ‌های تیره، کرم بودن سطح بتن، صیقلی نبودن سطح، وجود شیارهای بتن حاصل از قطع و بتن‌ریزی مجدد می‌تواند بر عدم دقت تشخیص ترک بیافزاید، که این مشکل با جامعیت بخشیدن بانک اطلاعاتی قابل برطرف کردن است [7].

پردازش تصویر از هر نوع پردازش سیگنال دیجیتال که ورودی یک تصویر است مثل عکس یا فیلم که با دوربین دیجیتال یا اسکن شده توسط اسکنر هستند سر و کار دارد [8]. پیشرفت روز افزون فناوری پردازش تصاویر در کنار انجام موازی محاسبات باعث تمایل محققان به پایش سلامت سازه از طریق تصویر شد. کوچ و همکاران [10] به تحقیق در مورد کارهای تحقیقاتی انجام شده مربوط به تشخیص نقص و ضعف بتن به وسیله روش‌های رایانه مینا پرداختند. در سال‌های اخیر روش‌های متعددی مانند خوشه‌بندی فازی، هیستوگرام سطح خاکستری، تحلیل طیفی و سایر روش‌ها برای تشخیص ترک در بتن ارائه شد [11, 12, 13]. همچنین از

شکل ۱. توانایی و میزان مشارکت یادگیری عمیق و یادگیری ماشین در روش هوش مصنوعی [28]

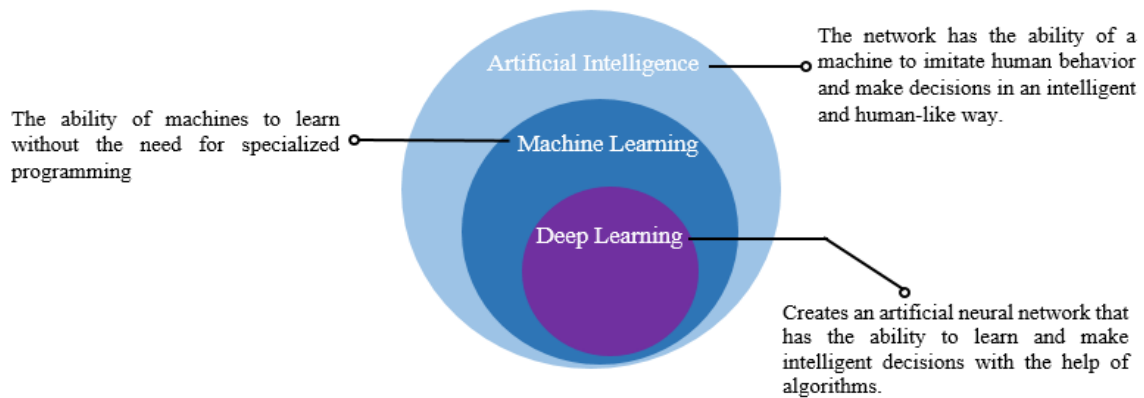


Fig. 1. Ability and extent of participation of deep learning and machine learning in artificial intelligence method [28]

ترکیبی شبکه عصبی کانولوشنی و Naive Bayes با تحلیل قاب به قاب فیلم‌های گرفته شده از سطح بتن توانستند ترک موجود در بتن را تشخیص دهند. در واقع آن‌ها با در نظر گرفتن هر قاب فیلم به عنوان یک تصویر این نوآوری را ارائه کردند.

بیگدلی و همکاران [3] با استفاده از روش شبکه عصبی کانولوشنی با استفاده از ۱۲۰۰۰ تصویر دیجیتالی، ترک در سازه‌های بتنی را طبقه‌بندی نمودند، در نتیجه این مطالعه تصاویر به کار برده شده با درستی ۹۹/۳ درصد در دسته‌های تصاویر بدون ترک، تصاویر دارای ترک ساده و تصاویر دارای چند شاخگی در ترک طبقه‌بندی شدند. لی و ژائو [25] با استفاده از شبکه عصبی پیچشی بهبود یافته با روش جستجوی جامع به دسته‌بندی تصاویر بتن ترک خورده و ترک نخورده پرداختند. با جمع‌آوری و تکمیل ۶۰ هزار تصویر بانک اطلاعاتی کاملی تشکیل دادند، که در نهایت آنها با استفاده از روش پیشنهادی (شبکه عصبی پیچشی بهبود یافته) توانستند با دقت ۹۹/۰۶ درصد دسته‌بندی تصاویر را به درستی انجام دهند.

پژوهش‌های متعدد دیگری با استفاده از روش شبکه عصبی کانولوشن و یا ترکیب آن با سایر روش‌ها استفاده شد، که تمامی آن‌ها از قابلیت کاربردی شدن برخوردار می‌باشند [26, 27].

مطالعه حاضر در مقایسه با مطالعات مشابه پیشین، دارای بانک

از همین رو پیشرفت‌ها در این حوزه مربوط به بخش تشخیص مرزهای (لبه‌ها) ترک می‌باشد، مانند تبدیل موجک، تبدیل سری فوریه، تشخیص مرزهای تصویر به روش سوبل و کئی و غیره [18, 19].

عوامل تأثیرگذار بر تصاویر مانند روشنایی روز و یا سایه موضعی اجسام روی سطوح و ... تأثیر چندانی بر روش شبکه عصبی کانولوشن ندارند و روش شبکه عصبی کانولوشن می‌تواند خطوط ترک را در چنین شرایطی نیز تشخیص دهد. در این روش برای تشخیص دقیق‌تر و قابل اعتمادتر از روش‌های یادگیری ماشین استفاده شده است. می‌توان از شبکه عصبی مصنوعی، یادگیری با ناظر ماشین و یا سایر روش‌های دسته‌بندی برای طبقه‌بندی تصاویر به دو وضعیت کیفی ترک‌خورده و ترک نخورده بهره برد [20, 21].

با توجه به پیشرفت روز افزون توانایی محاسبات انجام گرفته شده توسط رایانه به صورت موازی و رفع بسیاری از محدودیت‌ها در پردازش تصویر به دلیل بهره‌مندی از دانش پردازش واحد گرافیکی، شبکه عصبی مصنوعی اعتماد بیشتری را در طبقه‌بندی تصاویر به لحاظ کیفی جلب نموده است [23]. حال این روش امکان استفاده از گوشی تلفن همراه هوشمند را در ارزیابی عملکرد سلامت سازه مقدور نموده و دستیابی به برآورد اولیه از سلامت و پایداری سازه بعد از بارگذاری‌های غیرمعمول مانند انفجار، زلزله و ... را فراهم نموده است [24]. چن و جهان‌شاهی [26] با استفاده از روش

اندازه 4032×3024 به دست آمده است [28]. روش تفکیک به این صورت است یک تصویر با ابعاد 4032×3024 توسط یک پنجره 227×227 به 221 تصویر تفکیک می‌شود. پس از دسته‌بندی به صورت دستی بانک اطلاعاتی آماده می‌شود. شکل (۲) به عنوان نمونه خطوط تفکیک یک تصویر را نشان می‌دهد. هدف از این تفکیک افزایش بانک اطلاعاتی موجود به منظور آموزش هرچه بهتر شبکه طراحی شده می‌باشد. از این تعداد $20,000$ عدد تصویر در دسته ترک خورده و $20,000$ عدد تصویر در دسته ترک نخورده جای گرفته است. به منظور بررسی و ارزیابی دقیق‌تر، تصاویر به نسبت 4 به 1 و به صورت تصادفی برای آموزش و راستی‌آزمایی شبکه عصبی کانولوشنی دسته‌بندی شده‌اند. به عبارت دیگر $16,000$ تصویر بتن در هر دسته ترک خورده و ترک نخورده برای آموزش شبکه و $4,000$ تصویر بتن ترک خورده و ترک نخورده دیگر برای راستی‌آزمایی طبقه‌بندی شده است [28]. در شکل (۳) چند نمونه از تصاویر بتن ترک خورده و شکل (۴) چند نمونه از بتن ترک نخورده نشان داده شده است.

شکل ۳. چند نمونه تصویر بتن ترک خورده [28]



Fig. 3. Some examples of cracked concrete image [28]

شکل ۴. چند نمونه تصویر بتن ترک نخورده [28]



Fig. 4. Some examples of uncracked concrete image [28]

اطلاعاتی وسیع، دقت تشخیص بهتر و همچنین صرف‌زمان کمتر می‌باشد. در این پژوهش، از شبکه عصبی کانولوشن برای تشخیص ترک در سازه‌های بتنی در شرایط مختلف تصاویر (ترک خورده و ترک نخورده)، استفاده شده است. این شبکه قادر به دسته‌بندی تصاویر به دو دسته کیفی ترک‌خورده و ترک‌نخورده می‌باشد. اهداف اصلی تحقیق حاضر عبارتند از: ۱- کاربرد داده‌های با حجم و تنوع بسیار بالا نسبت به تحقیقات پیشین ۲- معرفی یک ساختار شبکه عصبی کانولوشنی منسجم، دقیق و کارآمد با کاربرد لایه‌های مختلف کانولوشنی ۳- تشخیص ترک در سازه‌های بتنی با دقت حدود $98/16$ درصد با صرف‌زمان کمتر در ساختار شبکه عصبی کانولوشنی پیشنهادی نسبت به مطالعات پیشین.

۲- بانک اطلاعاتی استفاده شده

تصاویر به‌کار برده شده در این پژوهش از چندین ساختمان موجود در محوطه دانشگاه صنعتی خاورمیانه گرفته شده است [28]. تعداد کل تصاویر $40,000$ عدد می‌باشد، که هر تصویر به اندازه 227×227 پیکسل است، تصاویر دارای سه لایه رنگی قرمز، سبز و آبی می‌باشند. این تصاویر از تجزیه و تفکیک 458 تصویر گرفته شده با دوربین عکاسی حرفه‌ای به

شکل ۲. نمونه‌ای از خطوط تفکیک تصویر در سازه بتنی استفاده

شده در مطالعه حاضر [28]




Fig. 2. An example of image separation lines in concrete structures used in the present study [28]

۳- ساختار عملکرد شبکه عصبی کانولوشن (CNN)

یکی از بهترین ساختارهای عصبی توسعه یافته بر پایه شبکه‌های عصبی تصویر محور، که در مدل سازی ویژگی های تشخیص تصاویر قابلیت و کارآمدی بیشتری از خود به نمایش گذاشته است، ساختار شبکه‌های عصبی کانولوشنی است [9]. هدف از طراحی شبکه‌های عصبی کانولوشن، مدل سازی دقیق از چگونگی عملکرد سیستم بینایی انسان و ارتباط آن با ناحیه بینایی مغز است که وظیفه استخراج خودکار ویژگی های کلیدی، یادگیری تصاویر در یک ساختار عصبی مجتمع و همچنین، حذف افزونگی های احتمالی را بر عهده دارد [29].

شبکه‌های عصبی کانولوشنی در بخش های ابتدایی، از لایه های کانولوشنی و لایه های جمع آوری تشکیل شده اند. نورون های لایه های کانولوشنی توسط مجموعه ای از ضرایب (وزن های شبکه عصبی) به بخشی از نورون های لایه پیشین متصل می شوند. جمع ورودی های وزن دار در هر قسمت، از تابعی غیرخطی، موسوم به تابع فعال سازی، مانند تابع سیگموئید یا تابع یکسو شده خطی عبور می کند. این لایه ها وظیفه استخراج ویژگی ها از ورودی شبکه عصبی را به عهده دارند و ویژگی اصلی آنها استخراج ویژگی های محلی و پیوستگی بین این ویژگی هاست. در مقابل، لایه های جمع آوری وظیفه جمع ویژگی های مشترک را بر عهده دارند. در هر شبکه عصبی کانولوشنی تعدادی از لایه های جمع آوری و کانولوشنی به همراه توابع غیرخطی مانند تابع

یکسو شده خطی در کنار تعدادی لایه چگال (لایه دارای نورون های وزن دار یا نورون های دارای ضریب) با اتصالات کامل (و نه محلی) بین نورون ها کار استخراج ویژگی و طبقه بندی را انجام می دهند. وزن های بانک های فیلتر این شبکه ها نیز مانند سایر شبکه های عصبی با استفاده از قاعده بازگشت به عقب محاسبه می شود [30].

مطابق شکل (۵) ساختار کلی شبکه عصبی کانولوشنی را می توان به صورت زیر بیان کرد: لایه کانولوشنی، لایه تلفیق، لایه فعال ساز و لایه کاملاً متصل. بخش اول شامل استخراج خصوصیات تصویر می باشد که این ویژگی ها از تصویر ورودی با استفاده از لایه های کانولوشن و تلفیق به دست می آید. بخش دوم متشکل از یک شبکه عصبی کاملاً متصل است، که می توان در این قسمت از شبکه عصبی پرسپترون چند لایه استفاده کرد [9].

شبکه های عصبی کانولوشن مزایای مختلف دارند (۱) به طور خودکار استخراج کننده ویژگی محلی را یاد بگیرند (۲) در مقابل خطاهای کوچک در ورودی خیلی تغییر نمی کنند (۳) اصول به اشتراک گذاری وزن که به طور قابل توجهی تعداد پارامترهای آزاد را کاهش می دهد را به کار می گیرند و بنابراین قابلیت تعمیم را افزایش می دهند [31].

در ادامه بعضی مفاهیم به کار رفته در شبکه های عصبی کانولوشن بیان شده است. نورون های مصنوعی اصولاً واحدهای پردازشی هستند که بعضی عملیات محاسباتی را روی چندین متغیر ورودی انجام می دهند و معمولاً یک خروجی محاسبه شده را در طول تابع فعال سازی تولید می کنند.

شکل ۵. معماری اصلی کانولوشن تشکیل شده از بخش استخراج ویژگی و شبکه عصبی چند لایه [32]




Fig. 5. The main convolution architecture consists of the feature extraction section and the multilayer neural network [32]

غیرخطی در شبکه عصبی کانولوشن و آموزش غیرخطی آن است (کانولوشن یک فرآیند خطی است که از طریق ضرب و جمع المان‌ها به دست می‌آید). تابع فعال ساز رابطه (۲) را در یک بازه منفی و مثبت به بازه صفر و مثبت (عدد یک) طبق رابطه (۳) در یک بخش غیرخطی تبدیل می‌کند. اما با این وجود این تابع معایبی نیز دارد: خروجی‌ها مرکز صفر ندارند و مقادیر همواره مثبت هستند. گرادیان برای مقادیر کوچک‌تر از صفر از بین می‌روند که تکنیک‌های جدیدی برای غلبه بر این مشکل استفاده می‌شود [33].

در میان انواع مختلف لایه‌ها، مسئولیت استخراج ویژگی‌ها از عکس‌ها با لایه کانالوشن است. لایه‌های اول معمولاً ویژگی‌های سطح پایین (مانند لبه‌ها و خط‌ها و گوشه‌ها) را دریافت می‌کنند، در حالی که بقیه لایه‌ها ویژگی‌های سطح بالا (مانند قواعد، اشیا و شکل‌ها) را دریافت می‌کنند. پردازشی که در این لایه انجام می‌شود می‌تواند به دو فاز تقسیم شود:

(۱) گام کانالوشن که یک پنجره با اندازه ثابت (گام یا فاصله مشخص بین مرکز پنجره و مرکز عکس) روی عکس اجرا می‌شود و محدوده مورد نظر را تعریف می‌کند (۲) مرحله پردازش که از پیکسل موجود در پنجره به عنوان ورودی برای نورون‌ها استفاده می‌کند که سرانجام عمل استخراج ویژگی را از آن ناحیه مورد نظر انجام می‌دهد. اصولاً در مرحله آخر، درست مانند معادله (۱) هر پیکسل در وزن متناظر با خودش ضرب می‌شود و خروجی نورون را تولید می‌کند، بنابراین تنها یک خروجی جدید کوچکتر از عکس اصلی را به دست می‌دهد. بیشتر این ویژگی‌ها شبیه به هم هستند زیرا که هر پنجره می‌تواند پیکسل‌های پنجره دیگر را نیز در خود داشته باشد. تغییرات ویژگی‌ها به وسیله یک سری از عملیات‌ها روی ویژگی مشخص یک ناحیه خاص از عکس ایجاد شده است. مشخصاً پنجره با اندازه ثابت روی ویژگی‌های استخراج شده با لایه کانالوشن اجرا می‌شود و در هر مرحله عملیات بهینه‌سازی می‌شود [34].

لایه تلفیق به طور خاص به منظور کاهش ابعاد ماتریس ویژگی و برگرداندن خصوصیات بارز تصویر به کار می‌رود. تلفیق می‌تواند دو نوع عملیات ماکزیمم میانگین و ماکزیمم

به طوری که یک نورون مصنوعی یک بردار وزن $w=(w_1, w_2, \dots, w_n)$ و بعضی متغیرهای ورودی $x=(x_1, x_2, \dots, x_n)$ و یک آستانه یا جهت b (bias) را دارد. از دید ریاضی، بردارهای w و x بعد یکسانی دارند. پردازش کامل نورون ممکن است به صورت معادله (۱) بیان شود:

$$Z = F\left(\sum_i^N x_i w_i + b\right) \quad (1)$$

در حالی که z و x و w و b به ترتیب بیان کننده‌ی خروجی، ورودی، وزن و آستانه می‌باشند. $F(\cdot): \mathbb{R} \rightarrow \mathbb{R}$ تابع فعال ساز را بیان می‌دارد. به طور قراردادی، یک تابع غیرخطی برای $F(\cdot)$ در نظر گرفته می‌شود [33].

به طور کلی در شبکه عصبی، توابع فعال ساز برای به دست آوردن خروجی مطلوب از تابع ورودی استفاده می‌شوند. از توابع فعال‌سازی مختلفی می‌توان در شبکه‌های عصبی استفاده کرد. که مهم‌ترین آنها تابع فعال‌سازی سیگموئید، تانژانت هیپربولیک و تابع یکسو شده خطی است. یکی از توابع فعال‌ساز که در سال‌های اخیر مورد توجه قرار گرفته است، تابع یکسو شده خطی است. شبکه‌های جدید ترجیح می‌دهند به جای سیگموئید، از توابع فعال‌سازی یکسو شده خطی برای لایه‌های مخفی استفاده کنند. این تابع توسط کریز سوکی [33] ارائه شد. همان‌گونه که در رابطه (۱) مشاهده می‌شود، این تابع به همه پیکسل‌های تصویر وارد شده و تمام مقادیر منفی را صفر می‌کند و چندین مزیت دارند (۱) بهتر کار می‌کنند طوری که از اشباع برنامه در حین پردازش یادگیری دوری می‌کنند (۲) موجب عدم تراکم در واحدهای مخفی می‌شوند (۳) سریع‌تر از تابع سیگموئید و تابع تانژانت هیپربولیک عمل می‌کند و نرخ خطای آموزش را کاهش می‌دهد.

$$f(x) = \max(0, x) \Rightarrow f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases} \quad (2)$$

$$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases} \quad (3)$$

هدف از استفاده از تابع یکسو شده خطی تعریف یک بخش

شبکه عصبی کانولوشنی طراحی شده است. شبکه عصبی کانولوشن اگر دارای طرحی صحیح و مناسب باشد از توانایی شگرفی در دسته‌بندی نوشتار، تشخیص چهره و تشخیص ترک‌خوردگی در سازه‌های فولادی و بتنی برخوردار است. تداخل و درگیری بیشتر نورون‌ها، اشتراک اطلاعات مهم بین نورون‌ها و محاسبات هم‌ارز و موازی بین نورون‌ها سه ویژگی مهم و علت برتری شبکه عصبی کانولوشن نسبت به سایر مدل‌های مرسوم قدیمی است [35]. تکنیک‌های پردازش تصویر ترک‌های حاصل از تصاویر را براساس برخی فرضیات که ناحیه‌ها باریک و متصل هستند و تاریک‌تر از پس زمینه آنها هستند، شناسایی می‌کنند. برای استحکام بیشتر در تشخیص ترک، تغییرات کلی و تشخیص لبه‌های محلی مستقر می‌شوند. این روش بیش از حد به انتخاب مناسب تکنیک‌های پیش پردازش تصویر و تشخیص لبه تصویر، بستگی دارد. با این حال، ویژگی‌های موجود در سطح سازه متغیر هستند و تحت تأثیر عوامل زیادی در شرایط واقعی مانند نور، سایه و غیره قرار می‌گیرند.

برخلاف شبکه‌های عصبی مرسوم، شبکه‌های عصبی کانولوشنی طبقه‌بندی تصاویر به دلیل اتصالات جزئی، تقسیم وزن و روند جمع شدن بین سلول‌های عصبی، به محاسبات کمتری نیاز دارند. مطابق شکل (۶) در لایه کانولوشن ویژگی داده‌ها با توجه به نیاز ما استخراج می‌شود. در هر بلوک کانولوشن، تصویر یا همان ماتریس ورودی توسط تابع کرنل تبدیل می‌یابد و تمام مقادیر آن به همراه Bias جمع می‌شود. ضرایب و گام تابع کرنل باید بهینه شود که این بهینه‌سازی در طول فرآیند آموزش رخ می‌دهد. تمام مقادیر و متغیرهای ورودی در این لایه با تمام نورون‌ها ارتباط دارند که این خاصیت سبب کاهش محاسبات برای لایه‌های بعدی می‌شود. در توابع غیرخطی استفاده شده به عنوان تابع فعال ساز هدف اضافه نمودن بخش غیرخطی در خروجی شبکه عصبی کانولوشن می‌باشد. در بیشتر مدل‌های این روش تابع فعال‌ساز یکسو شده خطی عملکرد بهتری از خود نشان داده است. از همین رو در این پژوهش نیز از این تابع استفاده شده است.

جمع داشته باشد. این عملیات تضمین می‌کند که حتی وقتی که ویژگی‌های عکس تغییرات و چرخش‌های کوچکی را داشته باشند، همچنان نتیجه یکسان بماند، که برای تشخیص و طبقه‌بندی اشیاء ویژگی بسیار مهمی محسوب می‌شود. لایه کاملاً متصل مانند یک شبکه پرسپترون چند لایه است که در لایه خروجی از تابع فعال ساز بیشینه هموار استفاده می‌کند. لایه کاملاً متصل به این معنی است که تمام نورون‌ها در لایه قبل به طور کامل به تمام نورون‌های لایه بعدی متصل هستند. یکی از توابع محبوب در زمینه کلاس‌بندی، تابع بیشینه هموار است. این تابع تقریباً شبیه به تابع سیگموئید است، تنها با یک تفاوت که خروجی‌های این تابع به گونه‌ای نرمال‌سازی شده‌اند، که مجموع آن‌ها عدد یک باشد. در برخی از موارد از تابع ماشین بردار پشتیبان نیز استفاده می‌شود. اما با توجه به اینکه تابع بیشینه هموار گزارش دقیق‌تری از احتمال یک کلاس را به ما می‌دهد برای فرآیند کلاس‌بندی مناسب‌تر است. احتمال هر کلاس از فرمول زیر محاسبه می‌شود.

$$P(y_i | x_i; W) = \frac{e^{f_j}}{\sum_j e^{f_j}} = \frac{C e^{f_j}}{C \sum_j e^{f_j}} = \frac{e^{f_j + \log C}}{\sum_j e^{f_j + \log C}} \quad (4)$$

در اینجا y_i کلاس صحیح برای تصویر x_i است. اگر ما به صورت و مخرج ثابتی مثل C اضافه کنیم در جواب تفاوتی ایجاد نمی‌کند، اما تحلیل را می‌تواند ساده‌تر کند. در این لایه یک مقدار رایج برای این ضریب $\log C = -\max_i f_i$ است [33].

۴- ساختار شبکه عصبی کانولوشنی مطالعه حاضر

در این مقاله، روشی برای تشخیص ترک مبتنی بر شبکه‌های عصبی کانولوشن برای سطح بتن واقعی پیشنهاد شده است. شبکه‌های عصبی کانولوشن می‌توانند به جای استخراج ویژگی‌ها، به طور خودکار ویژگی‌های تصاویر را یاد بگیرند. یک شبکه عصبی کانولوشن که برای تشخیص ترک استفاده می‌شود از طریق تنظیم دقیق متغیرهای یک ساختار موجود

شکل ۶. شماتیک لایه‌های کانولوشن و لایه‌های تلفیق برای یک نمونه تصویر بتن ترک خورده [8]




Fig. 6. Schematic drawing of convolution layers and compilation layers for a cracked concrete image sample [8]

علاوه، باید توجه داشت که اگر تعداد دوره‌ها بیش از حد زیاد باشد، ممکن است منجر به بیش‌برازش شود. در نهایت و پس از مرحله اعتبارسنجی یک مدل یادگیری عمیق، کارایی آن روی مجموعه داده‌های آزمایش ارزیابی می‌شود. در واقع هنگامی که یک شبکه عمیق آموزش می‌بیند و برازش می‌شود، این شبکه سعی می‌کند خروجی را روی داده‌های آزمایش هر چه دقیق‌تر پیش‌بینی کند که میزان درستی پیش‌بینی به دست آمده روی داده‌های آزمایش، در صد درستی را تشکیل می‌دهد.

برای آموزش شبکه عصبی کانولوشن طراحی شده، در طول مشاهده تصاویر مربوط به آموزش، ضرایب شبکه و Bias بهینه می‌شوند. پس از بهینه‌سازی این ضرایب توسط تکرار الگوریتم بهینه‌سازی شبکه وارد مرحله اعتبارسنجی و در نهایت راستی‌آزمایی می‌شود. ضرایب شبکه و متغیر Bias برای اولین بار و قبل از بهینه‌شدن به ترتیب توسط روش Xavier و Constant تعیین می‌شوند. فرآیند بهینه‌سازی توسط گرادینت نزولی تصادفی با مونتوم انجام می‌شود. مقدار مونتوم اولیه مفروض برای این روش $0/9$ و نرخ تغییر ضرایب آموزشی نیز $0/01$ در نظر گرفته شده است. شبکه عصبی کانولوشن با 250 تکرار، آموزش و اعتبارسنجی می‌شود به این صورت که تصاویر با ابعاد پنجره 32 پیکسل تبدیل و تفکیک می‌شوند. بعد از پنجره 32 پیکسلی پنجره 16 و 8 پیکسلی فیلتر سیون تصاویر را انجام می‌دهند. مجموعاً 3 مرحله فیلتر 32 ، 16 و 8 پیکسلی تصاویر را تحلیل و تفسیر می‌نمایند. سپس $16,000$ تصویر مربوط به آموزش 250 تکرار را انجام می‌دهند. در

در لایه تلفیق خروجی محاسبه شده توسط لایه‌های قبل به اندازه پنجره‌ای با ابعاد همسان با لایه کانولوشن تولید می‌شود. در حالت کلی دو نوع لایه تلفیق وجود دارد حالتی که از مقدار بیشینه مقادیر هر بلوک استفاده می‌کند و حالتی که از مقدار میانگین هر بلوک استفاده می‌کند. معمولاً حالت اول یعنی بهره‌مندی از بیشینه مقدار هر بلوک عملکردی رضایت‌بخش‌تری از خود نشان می‌دهد. تصاویر با $3 \times 227 \times 227$ پیکسل به شبکه عصبی کانولوشنی وارد می‌شوند و لایه‌های تابع بیشینه هموار پیش‌بینی می‌کنند که آیا هر تصویر ورودی ترک خورده است یا ترک نخورده.

۵- بحث و نتایج

در این بخش به تشریح مشخصات فرض شده برای شبکه عصبی کانولوشنی برای تشخیص ترک در سازه‌های بتنی پرداخته شده است. در شبکه‌های عصبی کانولوشنی که خروجی به صورت جفت است، شامل تصاویر ترک‌خورده و ترک‌نخورده معماری شبکه تقریباً با هم یکسان هستند، فقط در مشخصات جزئی با هم تفاوت دارند. کل تصاویر ورودی با ابعاد $3 \times 227 \times 227$ پیکسل به شبکه داده شد. عدد 3 نشان دهنده سه لایه رنگی قرمز، سبز و آبی استفاده شده در تصاویر است. لایه خروجی دارای دو نورون (گره) با عنوان ترک خورده و ترک‌نخورده است که تصویر ورودی را با توجه به اطلاعات استخراجی از تبدیل کانولوشن انجام شده روی آن دسته‌بندی می‌نماید. تابع کرنل به دلیل کاهش حجم و زمان انجام محاسبات به جای 5×5 از 1×1 استفاده شده است.

تصویر ورودی ارائه شده به شبکه است. در واقع یک سطح انتزاع به سطح انتزاع دیگری تبدیل شده است و صفحات ویژگی در شبکه‌های عصبی عمیق به ویژه در لایه‌های بالاتر به صورت تصاویر با وضوح نسبتاً پایین دیده می‌شوند. به همین دلیل و برای پرهیز از نمایش تصاویر صفحات ویژگی با وضوح پایین و همچنین برای نمایش مناسب تغییرات هر لایه، بهترین خروجی هر بلوک به تصویر کشیده می‌شود تا میزان درصد خطا به حداقل مقدار خود برسد. که در شکل (۷) و (۸) با نقطه Final مشخص شده است. منظور از دقت تخمین محاسبه رابطه (۱) است.

$$\text{Accuracy}(\%) = \frac{\sum \text{Correctly Classified} (= 3992 + 3861)}{\text{Validation Data Number} (= 8000)} \times 100 \quad (5)$$

طول فرآیند آموزش هر ۲۰ تکرار یکبار اعتبارسنجی انجام شده و نمودار مربوط به دقت تخمین شبکه کانولوشن و خطای دسته‌بندی داده‌ها ترسیم و تکمیل می‌شود. همان‌گونه که مشخص است پس از اعمال لایه تلفیق، ابعاد صفحات ویژگی کاهش پیدا کرده است.

شکل (۷) نمودار نهایی حاصل از دقت تخمین و درصد اعتبارسنجی و تغییرات مقدار تابع هزینه را به ازای هر تکرار نشان می‌دهد که اعمال این شبکه روی داده‌های آزمایش معماری و مبانی روش پیشنهادی است. و شکل (۸) نیز خطای حاصل از تخمین را به ازای هر تکرار نشان می‌دهد. لازم به ذکر است که تصویر ورودی در طی مسیرش در لایه‌های کانولوشن و ادغام، دچار تبدیلات مختلفی می‌شود و صفحات ویژگی موجود در لایه‌های انتهایی شبکه متفاوت با

شکل ۷. دقت تشخیص شبکه عصبی کانولوشن به ازای هر تکرار




Fig. 7. Accuracy of convolutional neural network detection per repetition

شکل ۸. خطای تشخیص شبکه عصبی کانولوشن به ازای هر تکرار




Fig. 8. Convolution neural network detection error per repetition

است که در مقابل محور افقی یعنی داده‌های مشاهداتی به صورت تفکیکی مشخص شده است. با توجه به ماتریس درهم ریختگی ۳۸۶۱ تصویر یعنی ۴۸/۳ درصد به درستی ترک خورده پیش‌بینی شده و ۳۹۹۲ تصویر معادل ۴۹/۹ درصد نیز به درستی ترک نخورده و مجموعاً ۱۴۷ تصویر نادرست پیش‌بینی شده است که معادل ۱/۸ درصد می‌باشد. شکل (۱۰) نمونه تصاویری را با پیش‌بینی نادرست توسط شبکه عصبی کانولوشنی پیشنهادی را نشان می‌دهد. تمام فرآیند آموزش و اعتبارسنجی در زمانی ۵۲ دقیقه‌ای انجام شده است. با مشاهده شکل (۱۰) تصاویری که ترک خورده بوده و به اشتباه ترک نخورده پیش‌بینی شده‌اند. دارای خطوط ترک در گوشه تصویر یا ترک با عرض خیلی کم بوده‌اند، که شبکه عصبی کانولوشن پیشنهادی به دلیل عرض خیلی کم ترک یا موقعیت ترک دچار اشتباه شده است.

جدول ۱. ماتریس درهم ریختگی

Predictable and real results	Uncracked	Cracked
Uncracked	3992 Images 49.9 Percent	8 Images 0.1 Percent
Cracked	139 Images 1.7 Percent	3861 Images 48.3 Percent

Table 1. Clutter matrix

شکل ۹. ماتریس درهم ریختگی

		Confusion Matrix		
		Cracked	NonCracked	
Output Class	Cracked	3861 48.3%	8 0.1%	99.8% 0.2%
	NonCracked	139 1.7%	3992 49.9%	96.6% 3.4%
		96.5% 3.5%	99.8% 0.2%	98.2% 1.8%
		Cracked	NonCracked	
		Target Class		

برای ارزیابی عملکرد ساختار کانولوشن پیشنهادی در تشخیص ترک در سازه‌های بتنی از معیارهای کمی درستی، دقت و فراخوانی داده‌ها به کار برده شد. درستی، بدین مفهوم است که مدل آموزش دیده تا چه اندازه خروجی را صحیح تخمین می‌زند. دقت نشانگر میزان اعتماد به خروجی طبقه‌بندی و فراخوانی نیز کارایی طبقه‌بندی را با ملاحظه تعداد رخداد یک طبقه خاص نشان می‌دهد. این معیارها به صورت زیر هستند.

$$A_{cc} = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

$$P_r = \frac{TP}{TP+FP} \quad (7)$$

$$R_e = \frac{TP}{TP+FN} \quad (8)$$

که TP ، تعداد تصاویری است که به درستی توسط الگوریتم به یک طبقه انتساب یافته، TN ، تعداد تصاویری است که با وجود اینکه متعلق به یک طبقه نبوده‌اند، به درستی در آن طبقه نیز پیش‌بینی نشدند، FN ، تعداد تصاویری است که با وجود اینکه متعلق به یک طبقه نبوده‌اند، به سایر طبقه‌ها تعلق گرفته‌اند و در نهایت FP ، تعداد تصاویری است که با وجود اینکه متعلق به یک طبقه نبوده‌اند ولی در آن طبقه پیش‌بینی شدند. Acc ، Pr و Re نیز به ترتیب صحت، دقت و فراخوانی را نشان می‌دهند.

به منظور ارزیابی دقت و عملکرد الگوریتم، هر دسته‌بندی در مقابل دقت کلی انجام شده، ماتریس درهم ریختگی در جدول (۱) و شکل (۹) برای داده‌های راستی‌آزمایی نشان داده شده است. اثر بخشی بهتر، عملکرد بهتر توسط ماتریس درهم ریختگی مورد بررسی قرار می‌گیرد. این ماتریس می‌تواند عملکرد سیستم یادگیری ماشین را بررسی کند. این ماتریس یک روش اندازه‌گیری عملکرد برای مساله طبقه‌بندی یادگیری ماشین است که در آن خروجی می‌تواند دو یا چند کلاس باشد. شکل (۹ با ۴) ترکیب مختلف از مقادیر پیش‌بینی شده و واقعی ساخته شده است.

در ماتریس درهم ریختگی محور قائم خروجی مدل پیشنهادی

می‌باشد. در حالی که مطالعه حاضر دارای ۴۰,۰۰۰ تصویر و زمان تقریبی فرآیند تشخیص ترک ۵۲ دقیقه می‌باشد. در مطالعه حاضر از اعضای اصلی سازه بتنی (تیر، ستون و دال) استفاده شده در حالی که در مطالعه بیگدلی و همکاران [3] از تصاویر دیوارهای سیمانی نیز استفاده شده که با اهمیت بررسی ترک در تناقض می‌باشد.

جدول ۳. مقایسه درستی شبکه عصبی کانولوشنی پیشنهادی با

سایر روش‌های معرفی شده

Method used	Accuracy (percentage)
SVM, 1993 [11]	92
SVM, 2002 [12]	86.4
ANN, 2011 [16]	91
Deep learning, 2018 [23]	92
Proposed CNN	98.16

Table 3. Comparison of the accuracy of the proposed convolution neural network with other introduced methods

۶- نتیجه‌گیری

در این پژوهش به تشخیص سازه‌های بتنی ترک‌خورده و ترک‌نخورده با استفاده از روش شبکه عصبی کانولوشنی پرداخته شده است. برای این منظور یک بانک اطلاعاتی با تعداد ۴۰,۰۰۰ تصویر تهیه و جمع‌آوری شد. که از این میان ۸۰ درصد برای آموزش و ۲۰ درصد باقیمانده برای اعتبارسنجی و واسنجی روش به کار رفته، استفاده شد. ابعاد تصاویر استفاده شده $3 \times 227 \times 227$ بوده، همچنین ورودی در شبکه عصبی کانولوشن ایجاد شده تصویر سطح بتن و خروجی نیز به صورت جفت کیفی با عناوین ترک‌خورده و ترک‌نخورده می‌باشد. آموزش شبکه عصبی کانولوشن توسط روش گرادینت کاهشی تصادفی با گشتاور و با تابع فعال‌ساز یکسو شده خطی انجام شد و همچنین برای آموزش شبکه عصبی کانولوشن ارائه شده ۲۵۰ تکرار مورد بررسی قرار گرفت که به تدریج از میزان خطا کاسته و به دقت تشخیص و تمیز بتن ترک‌خورده و نخورده افزوده شد. نهایتاً مدل ارائه شده با دقت $98/16$ درصد در تشخیص بتن ترک‌خورده کارایی و قابل اعتماد بودن خود را نشان داد. به منظور ارزیابی دقت و عملکرد الگوریتم، هر دسته‌بندی در مقابل دقت کلی انجام شده، ماتریس درهم‌ریختگی برای داده‌های راستی‌آزمایی به کار گرفته شد. با

Fig. 9. Confusion Matrix

با توجه به جداول (۲ و ۳) شبکه عصبی کانولوشنی پیشنهادی نسبت به مطالعات پیشین دارای درصد درستی پیش‌بینی و زمان تقریبی بهتری بوده، همچنین روش پیشنهادی دارای دقت بهتری نسبت به سایر روش‌های پیشنهادی است.

شکل ۱۰. نمونه تصاویر ترک‌خورده که با پیش‌بینی نادرست ترک

نخورده [28]



Fig. 10. Sample of cracked images uncracked by incorrect prediction [28]

جدول ۲. مقایسه درستی و زمان اجرای شبکه عصبی کانولوشنی

پیشنهادی با برخی شبکه‌های معتبر

CNN	Prediction accuracy percentage	Approximate total process time (minutes)
Alex Net [36]	79	1730
Alex Net [37]	88.9	-
Alex Net [38]	87.91	-
VGG Net [39]	86.4	1551
Google Net [40]	94.2	457
CNN [3]	99.3	76
CNN [18]	97.95	-
Faster R-CNN [6]	89.7	-
Proposed CNN	98.16	52

Table 2. Comparison of the accuracy and execution time of the proposed CNN with some valid networks

با توجه به تشابه روش مطالعه حاضر با مطالعه بیگدلی و همکاران [3] دو پژوهش به اختصار مقایسه می‌شود، در مطالعه بیگدلی و همکاران [3] از ۱۶,۰۰۰ تصویر استفاده شده، همچنین زمان تقریبی تشخیص طبقه‌بندی ترک ۷۲ دقیقه

concrete and asphalt civil infrastructure. *Advanced Engineering Informatics*, 29 (2), pp.196-210.

[11] Kaseko, M.S., and Ritchie, S.G., 1993. A neural network-based methodology for pavement crack detection and classification. *Transportation Research Part C: Emerging Technologies*, 1(4), pp.275-291.

[12] Liu, Z., Suandi, S.A., Ohashi, T., Ejima, T., 2002. Tunnel crack detection and classification system based on image processing. in: *Machine Vision Applications in Industrial Inspection X, International Society for Optics and Photonics*, pp.145-152.

[13] Sato, Y., Bao, Y., Koya, Y.J., 2018. Crack detection on concrete surfaces using V-shaped features. *World of Computer Science & Information Technology Journal*, 8 (1).

[14] Davoudi, R. Miller, G.R. and Kutz, J.N. 2018. Structural load estimation using machine vision and surface crack patterns for shear-critical RC beams and slabs. *Journal of Computing in Civil Engineering*, 32(4), 04018024.

[15] Zhang, L., Yang, F., Zhang, Y.D., and Zhu, Y.J., 2016. Road crack detection using deep convolutional neural network. In *2016 IEEE international conference on image processing (ICIP)*, 3708-3712, IEEE.

[16] Moon, H., and Kim, J., 2011. Intelligent crack detecting algorithm on the concrete crack image using neural network. *Proceedings of the 28th ISARC*, pp.1461-1467.

[17] Yamaguchi, T., Nakamura, S., Saegusa, R., Hashimoto, S., 2008. Image-based crack detection for real concrete surfaces. *IEEJ Transactions on Electrical and Electronic Engineering*, 3(1), pp.128-135.

[18] Cha, Y-J., Choi, W., and Büyüköztürk, O. 2017. Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), pp.361-378.

[19] Yeum, C.M., Dyke, S.J., 2015. Vision-based automated crack detection for bridge inspection. *Computer-Aided Civil and Infrastructure Engineering*, 30(10), pp.759-770.

[20] Liu, S.-W., Huang, J.H., Sung, J.-C., Lee, C., 2002. Detection of cracks using neural networks and computational mechanics. *Computer methods in applied mechanics and engineering*, 191 (25-26) pp.2831-2845.

[21] Moselhi, O., and Shehab-Eldeen, T., 2000. Classification of defects in sewer pipes using neural networks. *Journal of infrastructure systems*, 6(3), pp. 97-104.

[22] McClelland, C., 2017. The Difference between artificial intelligence, machine learning, and deep learning. Retrieved February 13, p.2018.

[23] Nhat-Duc, H., Nguyen, Q.-L., Tran, V.-D., 2018. Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network. *Automation in Construction*, 94, pp.203-213.

[24] Zhao, X., Han, R., Yu, Y., Hu, W., Jiao, D., Mao, X., Li, M., and Ou, J., 2017. Smartphone-based mobile testing technique for quick bridge cable-force

توجه به ماتریس درهم ریختگی ۳۸۶۱ تصویر یعنی ۴۸/۳

در صد به درستی ترک‌خورده پیش‌بینی شده و ۳۹۹۲ تصویر

معادل ۴۹/۹ درصد نیز به درستی ترک‌نخورده و مجموعاً ۱۴۷

تصویر نادرست پیش‌بینی شده است که معادل ۱/۸ در صد

می‌باشد. لازم به ذکر است که از این روش و بانک اطلاعاتی

می‌توان برای تولید برنامه تشخیص ترک در گوشی هوشمند

نیز با تولید اپلیکیشن بهره‌مند شد.

۷- مراجع

[1] ASCE. 2017. *Infrastructure Report Card, Asce Reston*. VA, USA.

[2] Cook, W., and Barr, P.J., 2017. Observations and trends among collapsed bridges in New York State. *Journal of Performance of Constructed Facilities*, 31 (4), pp.04017011.

[3] Bigdeli, N., Jabbari, H., and Shojaei, M., 2021. An intelligent method for crack classification in concrete structures based on deep neural networks. *Amirkabir Journal of Civil Engineering*, 53(8), pp. 1-13. (DOI): 10.22060/CEEJ.2020.17738.6660.

[4] Xu, Y., Wei, S., Bao, Y., and Li, H., 2019. Automatic seismic damage identification of reinforced concrete columns from images by a region-based deep convolutional neural network. *Structural Control and Health Monitoring*, 26 (3), pp.1-22.

[5] Valença, J., Puente, I., Júlio, E., González-Jorge, H., Arias-Sánchez, P., 2017. Assessment of cracks on concrete bridges using image processing supported by laser scanning survey. *Construction and Building Materials*, 146, pp.668-678.

[6] Cha, Y-J., Choi, W., Suh, G., Mahmoudkhani, S., and Büyüköztürk, O., 2018. 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.

[7] Li, S., and Zhao, X., 2018. Convolutional neural networks-based crack detection for real concrete surface. In *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 10598 (105983)*. *International Society for Optics and Photonics*.

[8] Ryu, E., Kang, J., Lee, J., Shin, Y., and Kim, H., 2020. Automated detection of surface cracks and numerical correlation with thermal-structural behaviors of Fire damaged concrete beams. *International Journal of Concrete Structures and Materials* 14, pp.1-12.

[9] Edraki, A., and Razminia, A., 2018. Classification of white blood cells using convolutional neural network. *ISMJ*, 21(1), pp.65-80. (in persian)

[10] Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., and Fieguth, P., 2015. A review on computer vision based defect detection and condition assessment of

- [33] Moghasemi, H.R., Vasli, E., Manafi, S., 2018. Classify recorded images remotely using CNN deep learning algorithm. *Congress of New Research Ideas in Engineering and Technology, Electrical and Computer Science*. (in persion)
- [34] Bai, X., Shi, B., Zhang, C., Cai, X., and Qi, L., 2017. Text/non-text image classification in the wild with convolutional neural networks. *Pattern Recognition*, 66, pp.437-446.
- [35] Kim, J.H., Hong, G.H., and Park, K.R., 2017. Convolutional neural network-based human detection in nighttime images using visible light camera sensors. *17(5)*, 1065 (2017).
- [36] Nawaz, W., Ahmed, S., Tahir, A., and Khan, H.A., 2018. Classification of breast cancer histology images using alexnet Recognition. in: *International Conference Image Analysis and Recognition*, Springer, pp.869-876.
- [37] Dhakal, N., Zihan, Z.U.A., Elseifi, M.A., Mousa, M.R., Gaspard, K., and Fillastre. C.N., 2020. Surface identification of top-down, bottom-up, and cement-treated reflective cracks using convolutional neural network and artificial neural networks. *Journal of Transportation Engineering, Part B: Pavements*, 147(1), 04020080.
- [38] Wang, Z., Xu, G., Ding, Y., Wu, B., and Lu, G., 2020. A vision-based active learning convolutional neural network model for concrete surface crack detection. *Advances in Structural Engineering* 1369433220924792.
- [39] Kim, M.-K., 2018. Contactless palmprint identification using the pretrained VGGNet model. *Journal of Korea Multimedia Society*, 21(12), pp.1439-1447.
- [40] Al-Qizwini, M., Barjasteh, I., Al-Qassab, H., Radha, H., 2017. Deep learning algorithm for autonomous driving using googlenet. in: *2017 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, pp.89-96.
- measurement. *Journal of Bridge Engineering*, 22(4), 06016012.
- [25] Li, S., and Zhao, X., 2019. Image-based concrete crack detection using convolutional neural network and exhaustive search technique. *Advances in Civil Engineering*, 2019.
- [26] Chen, F.-C., and Jahanshahi, M.R., 2018. Video-based crack detection using deep learning and Nave Bayes data fusion. In *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2018*, p 105980J, International Society for Optics and Photonics.
- [27] Cha, Y.-J., and Choi, W., 2017. Vision-based concrete crack detection using a convolutional neural network. In *Dynamics of Civil Structures*, 2, 71-73, Springer.
- [28] Özgenel, Ç.F., 2019. Concrete crack images for classification. Mendeley Data, V2, DOI:10.17632/5y9wdsg2zt.2 or <https://data.mendeley.com/datasets/5y9wdsg2zt/2>.
- [29] Lomonaco, V., 2015. Deep learning for computer vision: a comparison between convolutional neural networks and hierarchical temporal memories on object recognition tasks.
- [30] McCann, M.T., Jin, K.H., Unser, M., 2017. Convolutional neural networks for inverse problems in imaging: A review. *IEEE Signal Processing Magazine*, 34(6), pp. 85-95.
- [31] Romanuke, V.V., 2017. Appropriate number and allocation of ReLUs in convolutional neural networks sensors. *Naukovi Visti NTUU KPI*, 1, pp.69-78.
- [32] Mohammadi-amin, F., Kouhestani, B., Dadashzadeh, B., 2017. Design and implementation of an improved deep learning system for image classification and comparison of its function with artificial neural network. *2nd International Conference on Knowledge-Based Research in Computer Engineering and Information Technology*. (in persion)

Crack Detection in Concrete Structures Using Convolutional Neural Network

M. Seifollahi¹, S. Abbasi², M. Fahimi-Farzam^{3*}, R. Daneshfaraz⁴

1- M.Sc, Graduated of Civil-Hydraulic Structures Eng, Faculty of Civil Eng, Univ. of Tabriz, Tabriz, Iran

2- M.Sc, Graduated of Civil-Hydraulic Structures Eng, Faculty of Eng., Univ. of Mohagheh Ardabili, Ardabil, Iran

3- Associate Professor of Civil Eng, Faculty of Eng, Univ. of Maragheh, Maragheh, Iran

4- Professor of Civil Eng., Faculty of Eng, Univ. of Maragheh, Maragheh, Iran

Received: 15/05/2021

Accepted: 06/03/2022

* M.farzam@maragheh.ac.ir

Abstract:

One of the active areas of research in concrete structure health monitoring is the detection of cracking in structural elements. Image classification and diagnosis have attracted the attention of many researchers nowadays. Due to the advancement of artificial neural networks and their fast processing, a convolution neural network has been established to detect these cracks. In this study, crack detection in concrete structures has been studied using a convolutional neural network, which can be generalized to all concrete structures for example dams, canals, bridges, shells, road infrastructure, foundations and concrete frames. Convolution neural network training was performed by the SGDM method with the ReLU activator function. Also, 250 iterations were employed for convolution neural network training, which gradually reduced the error rate and increased the accuracy of detecting cracked and uncracked concrete. The convolutional neural network is trained and validated with these 250 iterations. First, images with 32-pixel window dimensions are converted and separated. Then, the 32-pixel window, the 16-pixel, and the 8-pixel windows filter the images. A total of 3 stages of 32, 16, and 8-pixel filter images are analyzed and interpreted. During the training process, validation is performed every 20 iterations, and a diagram related to the accuracy of convolution network estimation and data classification error is drawn and completed. In convolutional neural networks, where the output is in pairs, the cracked and uncracked images of the network architecture are almost identical, differing only in minor specifications. The database of this research includes 20,000 images of cracked concrete and 20,000 uncracked concrete with dimensions of $3 \times 227 \times 227$ pixels, 80% of it is used for training and the remaining 20% is used for validation of the convolution neural network. The accuracy of distinguishing cracked concrete from uncracked ones is about 98.16%, which is acceptable for operation and is considered practical. To evaluate the accuracy and performance of the proposed algorithm, each classification was performed against the overall accuracy, the confusion matrix was used for the validation data. According to the clutter matrix, 3861 images, in other words, 48.3% have been predicted to be correctly cracked, and 3992 images, equivalent to 49.9%, have been predicted to be correctly uncracked, and a total of 147 incorrect images have been predicted, which is equivalent to 1.8 percent. Images that are cracked and not accidentally cracked are predicted. They had crack lines in the corner of the image or cracks with a very small width, which the proposed convolutional neural network was mistaken for due to a very small crack width or crack position. Also, the results of the present study showed that the accuracy of this research has the best accuracy in less analysis time compared to previous studies. It should be noted that this method and its associated database can be used to produce a crack detection application on a smartphone, to be able to make a good initial estimate of the structure in question, such as a bridge or building after an unusual loading event, such as an earthquake or explosion.

Keywords: Cracks in Concrete, Convolutional Neural Network, Structural Health Monitoring, Graphics Processing Unit.