

ارزیابی خودکار وضعیت روسازی جاده‌ای با استفاده از مدل شبکه مولد تخصصی با جریمه گرادیان و بخش‌بندی مبتنی بر U-Net

محمد صدیقیان فرد، امیر گل‌رو*

دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، ایران

*agolroo@aut.ac.ir

چکیده

توسعه مدل‌های یادگیری عمیق کارآمد در حوزه تشخیص و بخش‌بندی خودکار خرابی‌های روسازی آسفالتی با چالش جدی کمبود و عدم توازن داده‌های آموزشی مواجه است. پژوهش حاضر با هدف ارزیابی خودکار وضعیت روسازی و با فرضیه غلبه بر محدودیت‌های داده‌ای از طریق تولید داده‌های مصنوعی واقع‌گرایانه، رویکردی نوین را برای تشخیص و بخش‌بندی خودکار خرابی‌های آسفالتی ارائه داده است. در روش پیشنهادی، ابتدا از شبکه مولد تخصصی واسرشتان با جریمه گرادیان (WGAN-GP) به منظور تولید تصاویر باکیفیت و متنوع ترک با استفاده از مجموعه داده عمومی کرک ۵۰۰ استفاده شد تا ضمن جلوگیری از فروپاشی حالت، پایداری آموزش تضمین شود. سپس، یک مدل U-Net برای بخش‌بندی پیکسل به پیکسل بر روی مجموعه داده ترکیبی (واقعی و مصنوعی) آموزش داده شد. نوآوری اصلی این تحقیق در تلفیق معماری بهبودیافته GAN با مدل بخش‌بندی برای رفع مشکل بیش‌برازش و افزایش قابلیت تعمیم‌پذیری مدل در شرایط محیطی مختلف است. بررسی نتایج نشان می‌دهد که افزودن تصاویر مصنوعی، عملکرد مدل بخش‌بندی را به طور چشمگیری افزایش داده و منجر به کسب ضریب دایس ۰/۹۶۱ و شاخص اشتراک روی اجتماع ۰/۹۲۵ شده است. همچنین، ارزیابی عملکرد مدل توسعه یافته حاکی از توانایی بالای آن در شناسایی ترک‌های ریز و پیچیده در مجموعه داده‌های دیگر می‌باشد. در نهایت، با ادغام خروجی‌های مدل در یک شاخص وضعیت سطحی، چارچوب پیشنهادی توانایی ارزیابی هوشمند، دقیق و کم‌هزینه شرایط روسازی را فراهم کرده است.

کلمات کلیدی

سیستم مدیریت روسازی، شبکه مولد تخصصی با جریمه گرادیان (WGAN-GP)، بخش‌بندی ترک، مدل U-Net، شاخص وضعیت سطحی.

سیستم مدیریت روسازی^۱ (PMS) یک ابزار برنامه‌ریزی بوده که به متولی‌های جاده‌ای در فرآیند تصمیم‌گیری کمک می‌کند تا شبکه راه را به‌موقع و مقرون به صرفه حفظ کرده و همچنین آسایش و ایمنی کاربران را تضمین کند [1,2]. رویکرد برنامه‌ریزی سنتی برای تعمیر و نگهداری روسازی، بازسازی روسازی را پس از وقوع خرابی سازه‌ای قابل توجه در نظر می‌گیرد؛ به این صورت که این رویکرد منجر به بهسازی شدیدتر و گران‌تر شده که می‌تواند باعث ایجاد شرایط نایمن برای کاربران جاده قبل از اتخاذ تصمیم‌گیری‌ها شود [3]. با توجه به این ملاحظات مزایای حاصل از یک رویکرد فعال باید با برخی از معایب اولیه روبرو شود که منجر به تأخیر کلی در مقبولیت PMS در سراسر جهان شده است. هزینه‌های پیاده‌سازی سیستم و هزینه‌های عملیاتی برای جمع‌آوری و پردازش داده‌ها، عملیات‌های زمان‌بر، مانند بررسی و فرآیند داده‌ها، با در نظر گرفتن گسترش گسترده شبکه جاده‌ای، محدودیت‌هایی را نشان می‌دهند. در این راستا، تکرارپذیری، دقت و عینی بودن خرابی و تشخیص روسازی پیشرفت بسیار مهمی در این نوع فرآیند است [4].

جمع‌آوری داده‌های وضعیت روسازی با تغییرات چشمگیری در طول پیشرفت فناوری روبرو شده است. این کار با روش‌های کاغذی برای بررسی خرابی‌های روسازی آغاز شده، سپس جمع‌آوری داده‌های وضعیت روسازی به صورت دستی و خودکار بوده است. روندهای فعلی جمع‌آوری داده‌های روسازی مبتنی بر تلفن همراه بوده و در آینده نزدیک جمع‌آوری داده‌ها مبتنی بر خودروهای متصل^۲، خودران^۳ (AVs) غالب خواهد بود. تکامل روش‌های جمع‌آوری داده‌های روسازی نشان می‌دهد که چگونه فناوری نحوه جمع‌آوری، ذخیره و تجزیه و تحلیل داده‌ها رشد کرده است [5]. امروزه، با ظهور AVs، سیستم‌های حمل و نقل هوشمند دستخوش تغییرات چشمگیری شده که باید زیرساخت‌های جاده برای خدمت رسانی به آن‌ها آماده شوند [6]. این خودروها به دلیل داشتن قطعات مختلف تجهیزات برای تجزیه و تحلیل محیط خارجی، پتانسیل دریافت و انتقال حجم قابل توجهی از داده‌ها از جمله وضعیت روسازی را دارند [5].

ترک‌های روسازی یکی از انواع اصلی خرابی‌های راه هستند و همواره از دغدغه‌های کلیدی در بازرسی و نگهداری بزرگراه‌ها به شمار می‌آیند. اگر ترک‌ها به موقع تعمیر نشوند، می‌توانند به شکست سازه‌ای روسازی منجر شوند. بازرسی‌های منظم روسازی، تشخیص به موقع خرابی‌ها و انجام تعمیرات فوری برای جلوگیری از تبدیل ترک‌های جزئی به خرابی‌های جدی و در نتیجه تضمین دوام بلندمدت روسازی‌ها ضروری‌اند. تشخیص خودکار خرابی‌های روسازی بر تصاویر برداشت شده به وسیله ابزارهای مختلف تکیه دارد و عمدتاً از دو روش اصلی استفاده می‌کند: (۱) مدل‌های مبتنی بر پردازش تصویر^۴ (IP) و (۲) مدل‌های مبتنی بر یادگیری عمیق^۵ (DL) [7]. رویکردهای مبتنی بر پردازش تصویر، مانند آستانه‌گذاری، تشخیص لبه و تبدیلات حوزه‌ای، برای شناسایی ترک‌ها به کار می‌روند [8,9]. این روش‌ها مفروضاتی دارند؛ برای مثال فرض می‌کنند ترک‌ها تیره‌تر از محیط اطراف ظاهر می‌شوند یا تغییرات گرادیان نسبت به پس‌زمینه را نشان می‌دهند [۱۰]. با این حال، این مفروضات اغلب در شرایط پیچیده‌ای مانند حضور سایه یا نورپردازی نامتوازن ناکافی‌اند. پیشرفت‌های روش‌های یادگیری عمیق در بخش‌بندی^۶ روسازی، شناسایی ترک‌ها را به طور چشمگیری بهبود بخشیده‌اند. طی سال‌های اخیر، پیاده‌سازی الگوریتم‌های یادگیری عمیق کارآمد و دقیق برای بخش‌بندی و تشخیص^۷ خرابی روسازی به یک اولویت مهم تبدیل شده است [۱۱].

با وجود این پیشرفت‌ها، تهیه داده‌های باکیفیت برای آموزش الگوریتم‌های یادگیری عمیق همچنان چالشی جدی است. تعداد تصاویر ترک موجود در مجموعه داده‌های عمومی و در محل محدود است و این مقدار برای توسعه مدل‌های پیش‌بینی مبتنی بر DL ناکافی است [۱۲,۱۳]. علاوه بر این، نبود تعادل در داده‌ها می‌تواند عملکرد مدل را تحت تأثیر قرار دهد. یک مجموعه داده متنوع برای کاهش بیش‌برازش و افزایش دقت تشخیص ضروری است. روش‌های سنتی افزایش داده مانند مقیاس‌دهی، چرخش و آینه‌ای کردن تأثیر

¹ Pavement Management System

² Connected Vehicles

³ Autonomous Vehicles

⁴ Image Processing-based

⁵ Deep Learning-based

⁶ Segmentation

⁷ Detection

محدودی بر عملکرد مدل دارند؛ زیرا این روش‌ها ویژگی‌های جدید شبیه ترک یا پس‌زمینه‌های متنوع تولید نمی‌کنند و صرفاً تبدیلاتی از تصاویر اصلی ارائه می‌دهند. برای مقابله با این محدودیت‌ها، شبکه‌های مولد متخاصم^۱ (GANs) به عنوان روشی قدرتمند برای تولید مجموعه داده‌های تصاویر ترک پیشنهاد شده‌اند. این شبکه‌ها با تولید تصاویر مصنوعی اما واقع‌نمایانه تنوع داده‌ها را افزایش داده و آموزش مدل‌ها را بهبود می‌بخشد [۱۴]. GAN‌ها به ویژه به دلیل توانایی‌های قوی یادگیری‌شان برای افزایش تصاویر مورد استفاده قرار گرفته‌اند. این مدل‌ها [۱۵] می‌توانند مجموعه‌های داده مصنوعی ترک روسازی را تولید کرده و انواع مختلف ترک‌ها را مطابق نیازهای فرایندهای بخش‌بندی و تشخیص متنوع سازند. به عنوان یک استراتژی نوآورانه برای گسترش داده‌های تصویری، GAN‌ها کیفیت مجموعه داده‌های آموزشی را بهبود می‌بخشند و در نتیجه عملکرد مدل‌های پیش‌بینی مبتنی بر DL برای بخش‌بندی و شناسایی خرابی‌های روسازی را ارتقاء می‌دهند [۱۶].

با این وجود، آموزش GAN‌ها ممکن است با اشکالاتی مانند ناپدید شدن گرادیان^۲ و فروپاشی حالت^۳ مواجه شود که فرایند یادگیری مدل را مختل می‌کنند. برای غلبه بر این چالش‌ها، مدل شبکه مولد تخاصمی واسرشتاین با جریمه گرادیان^۴ (WGAN-GP) از فاصله واسرشتاین برای بهبود توازن در آموزش بهره می‌برد [۱۷]. این مدل از برش وزن‌ها^۵ برای حفظ پایداری استفاده می‌کند، هر چند این رویکرد می‌تواند تنوع تصاویر تولید شده را محدود کند. برای رفع این محدودیت‌ها و افزایش پایداری، نسخه‌ای از WGAN با جریمه گرادیان توسعه یافته است [۱۸]. این مدل تنوع تصاویر تولید شده را افزایش داده و مشکلات آموزش را تا حدی برطرف می‌سازد و آن را به جایگزینی مقاوم‌تر نسبت به GAN‌های سنتی تبدیل می‌کند. اگر چه تولید تصاویر با وضوح بالا همچنان برای WGAN-GP چالشی باقی مانده است، اما این روش رویکردی قابل اعتماد برای تولید داده‌های واقع‌نمایانه ارائه می‌دهد و پتانسیل خود را در زمینه‌هایی مانند ارزیابی روسازی آسفالتی نشان داده است. WGAN-GP به عنوان ابزاری مؤثر برای تولید داده‌های مصنوعی در کاربردهای دنیای واقعی برجسته می‌باشد، زیرا می‌تواند پایداری آموزش را افزایش و تنوع را گسترش دهد و در نتیجه عملکرد کلی پیش‌بینی را بهبود بخشد. مدل‌های متعددی از GAN توسعه یافته‌اند تا قابلیت‌های تولید تصویر آن‌ها بهبود یابد. شبکه‌های مولد شرطی (Conditional GANs — CGANs) برای تولید تصاویر از انواع مشخص با یک بردار نویز تصادفی معرفی شده‌اند [۱۹]. علاوه بر این، شبکه‌های CycleGANs برای انتقال سبک بین تصاویر توسعه یافته‌اند. این شبکه‌ها از دو مولد^۶ و دو تفکیک‌کننده^۷ استفاده می‌کنند تا تصاویر را بین حوزه‌ها تبدیل کنند. در حالی که محتوای کلیدی آن‌ها را حفظ می‌کنند و امکان تولید تصاویر با سبک‌های مختلف یا تصاویر تبدیل‌شده را فراهم می‌سازند [۲۰].

مائدا^۸ و همکاران [۲۱] از Progressive GAN (PG-GAN) برای تولید تصاویر خرابی چاله روسازی در اندازه 124×124 پیکسل استفاده کرده‌اند، در حالی که ما^۹ و همکاران [۲۲] شبکه‌ای با نام شبکه تخاصمی مولد ترک روسازی^{۱۰} (PCGAN) معرفی کرده‌اند که قادر به تولید تصاویر ترک در اندازه 256×256 پیکسل می‌باشد. ژو^{۱۱} و لیو^{۱۲} [۲۳] رویکردی برای بخش‌بندی و تشخیص ترک در نمونه‌های کوچک ارائه داده‌اند که مدل عمیق پیچشی^{۱۳} (DCGAN) و شبکه‌های عصبی پیچشی^{۱۴} (CNN) را ترکیب می‌کند. تصاویر بدون ترک، ترک‌های خطی و ترک‌های شبکه‌ای را در اندازه 224×224 پیکسل تولید کرده و مدل پیش‌بینی مبتنی بر CNN بر روی

¹ Generative Adversarial Networks

² Gradient Vanishing

³ Mode Collapse

⁴ Wasserstein Generative Adversarial Network with a Gradient Penalty

⁵ Weight Clipping

⁶ Generator

⁷ Discriminator

⁸ Maeda

⁹ Ma

¹⁰ Pavement Crack Generative Adversarial Network

¹¹ Xu

¹² Liu

¹³ Deep Convolutional GAN

¹⁴ Convolutional Neural Network

مجموعه داده گسترش یافته، توسعه یافته تا دقت شناسایی بهبود یابد. علاوه بر این، CrackGAN برای تشخیص ترک در سطح پیکسل توسعه یافته که نیاز به برچسب گذاری دقیق و نیروی انسانی را به طور قابل توجهی کاهش داده است [۲۴]. می^۱ و گل^۲ [۲۵] روشی برای تشخیص ترک روسازی ارائه داده اند که از مدل Conditional WGAN (CWGAN) برای تولید تصاویر مصنوعی ترک با کیفیت بالا بهره می برد.

کیو^۳ همکاران [۲۶] مدلی بر پایه GAN برای تقویت مجموعه داده های تصاویر ترک ارائه کردند و مدل گروه هندسه بصری^۴ (VGG) را برای طبقه بندی ترک بهبود بخشیده اند که منجر به افزایش ۹/۵ درصدی در دقت طبقه بندی نسبت به مدل VGG اولیه گردیده است. همچنین چارچوب توسعه یافته توسط ژانگ^۵ و همکاران [۲۷] عملکردی برتر نسبت به DCGAN نشان داده است. مدل های CNN که بخش مهمی از یادگیری عمیق هستند، چشم اندازهای قابل توجهی برای بخش بندی در سطح پیکسل اشیاء هدف در تصاویر نویزی ترک ارائه کرده اند [۲۸، ۲۹].

کونیگ^۶ و همکاران [۳۰] راهبردی جدید برای بخش بندی سطح جاده ارائه داده اند که معماری DL مبتنی بر مدل یونت^۷ است. بررسی نتایج نشان می دهد که یکپارچه سازی شبکه های رمزگذار از پیش آموزش دیده، عملکرد مدل را بهبود می بخشد. فن^۸ و همکاران [۳۱] نشان داده اند چگونه شبکه های عمیق پیچشی می توانند ترک ها را به عنوان خرابی بخش بندی و شناسایی کرده و ویژگی های قابل اندازه گیری مانند طول و اندازه ترک را استخراج نمایند. در پژوهشی دیگر [۳۲]، یک مدل U-Net^۷ بهبود یافته و پیشنهاد شده که دو ماژول شامل (۱) اتساع^۹ و (۲) ماژول پیچشی^{۱۰} و یادگیری سلسله مراتبی ویژگی^{۱۱} را در بر دارد تا عملکرد بخش بندی ترک را ارتقاء بخشد.

اگر چه مدل های یادگیری عمیق پتانسیل بالایی در تشخیص خودکار خرابی های روسازی دارند، اما کارایی و دقت آن ها به شدت وابسته به دسترسی به مجموعه داده های حجیم، برچسب گذاری شده و متنوع است. چالش بنیادین در این حوزه آن است که فرآیند جمع آوری و برچسب گذاری دقیق تصاویر خرابی در محیط واقعی، امری بسیار پرهزینه، زمان بر و گاه مخاطره آمیز است. افزون بر این، داده های موجود غالباً دچار عدم توازن شدید هستند؛ بدین معنا که تصاویر سالم به مراتب بیش از تصاویر خرابی است که این امر منجر به سوگیری مدل و کاهش کارایی در تشخیص خرابی های پیچیده می شود. از سوی دیگر، اگر چه مطالعات پیشین نشان داده اند که شبکه های مولد تخصصی نظیر WGAN-GP، PG-GAN و PCGAN پتانسیل خوبی برای تولید تصاویر مصنوعی و غلبه بر کمبود داده دارند، اما روش های سنتی افزایش داده توانایی تولید الگوهای جدید و متنوع را ندارند و پژوهش های موجود در زمینه GAN نیز همچنان با سه شکاف اصلی روبرو هستند: نخست، تمرکز اکثر مدل های فعلی بر ترک های ساده (مانند ترک های طولی و عرضی) است و نیاز مبرمی به روش های مؤثرتر برای تشخیص الگوهای پیچیده نظیر ترک پوست سوسماری احساس می شود. دوم، درصد بهینه داده های مصنوعی مورد نیاز برای رسیدن به حداکثر عملکرد مدل هنوز به طور جامع تعیین نشده است. سوم، تعمیم پذیری این مدل ها در شرایط متنوع واقعی و نوری مختلف نیازمند اعتبارسنجی دقیق تری است تا قابلیت اطمینان آن ها برای استقرار در سیستم های عملیاتی مدیریت روسازی تضمین گردد. بنابراین، مسئله اصلی این پژوهش، چگونگی غلبه بر محدودیت داده های آموزشی و پر کردن این شکاف های تحقیقاتی جهت بهبود دقت تشخیص خرابی ها و محاسبه شاخص وضعیت سطحی روسازی^{۱۲} (SCI) به صورت خودکار بدون نیاز به برداشت های میدانی گسترده است.

¹ Mei

² Gül

³ Que

⁴ Visual Geometry Group

⁵ Zhang

⁶ König

⁷ U-Net

⁸ Fan

⁹ Dilation

¹⁰ Convolution Module

¹¹ Hierarchical Feature Learning

¹² Surface Condition Index

هدف اصلی این پژوهش، توسعه یک چارچوب هوشمند و خودکار برای ارزیابی وضعیت روسازی جاده‌ای با تمرکز بر رفع چالش کمبود داده است. اهداف فرعی عبارت‌اند از:

۱. تولید تصاویر مصنوعی واقع‌گرایانه از ترک‌های آسفالت با استفاده از مدل مولد WGAN-GP برای رفع عدم تعادل داده‌ها؛
۲. بهبود دقت و قابلیت اطمینان مدل‌های بخش‌بندی با استفاده از داده‌های ترکیبی؛
۳. ارائه شاخص SCI خودکار مبتنی بر خروجی‌های مدل یادگیری عمیق برای تسهیل تصمیم‌گیری در سیستم‌های مدیریت روسازی.

همچنین این پژوهش درصدد پاسخگویی به سؤالات زیر است:

۱. آیا استفاده از شبکه مولد WGAN-GP می‌تواند تصاویری با کیفیت و تنوع کافی برای آموزش مدل‌های بخش‌بندی تولید کند؟
۲. افزودن چه میزان از داده‌های مصنوعی به مجموعه داده واقعی، بیشترین تأثیر را در بهبود دقت مدل بخش‌بندی U-Net دارد؟
۳. آیا مدل پیشنهادی قابلیت تعمیم‌پذیری مناسبی برای شناسایی خرابی‌ها در دیگر مجموعه داده‌های عمومی که دارای شرایط محیطی و نوری مختلف هستند را دارد؟

۲- تولید تصویر خرابی با مدل WGAN-GP و بخش‌بندی مبتنی بر یونت

این پژوهش از نظر هدف، کاربردی و از نظر ماهیت و روش، تجربی-تحلیلی است. فرآیند انجام پژوهش در یک چارچوب چهار مرحله‌ای سازماندهی شده است:

۱. آماده‌سازی داده‌ها: شامل پیش‌پردازش مجموعه داده عمومی کرک ۱۵۰۰ تغییر اندازه تصاویر به ابعاد 128×128 و نرمال‌سازی پیکسل‌ها؛
 ۲. تولید داده مصنوعی: توسعه مدل WGAN-GP بر روی داده‌های واقعی برای یادگیری توزیع آماری ویژگی‌های ترک و تولید تصاویر مصنوعی جدید جهت رفع عدم توازن داده‌ها؛
 ۳. مدل‌سازی و آموزش: طراحی و آموزش شبکه عصبی یونت با استفاده از ترکیب بهینه‌ای از تصاویر واقعی و مصنوعی برای وظیفه بخش‌بندی پیکسل به پیکسل خرابی‌ها؛
 ۴. ارزیابی و اعتبارسنجی: سنجش عملکرد مدل‌های مولد و بخش‌بندی با معیارهای ارزیابی عملکرد مدل‌ها (بخش ۲-۳-۲) و در نهایت محاسبه شاخص SCI برای کاربرد در مدیریت روسازی. تمامی مراحل مدل‌سازی و شبیه‌سازی در محیط زبان برنامه‌نویسی پایتون و با استفاده از کتابخانه‌های یادگیری عمیق پایتورچ و تنسورفلو اجرا شده‌اند.
- برای غلبه بر این چالش با استفاده از مجموعه داده‌های عمومی، از یک مدل مولد پیشرفته به نام WGAN-GP استفاده شده است تا تصاویر مصنوعی از خرابی‌های روسازی تولید شود. این تصاویر در کنار داده‌های واقعی، مجموعه داده‌های غنی‌تر و متنوع‌تر از انواع خرابی‌های روسازی را برای آموزش مدل‌های یادگیری عمیق فراهم می‌کنند.
- پس از تولید تصاویر خرابی، یک مدل بخش‌بندی عمیق برای تشخیص و تحلیل خرابی‌های روسازی توسعه داده شده است. استفاده از تصاویر تولید شده توسط مدل WGAN-GP به بهبود عملکرد آن کمک کرده و دقت تشخیص خرابی‌ها را افزایش داده است. در این بخش، روش پیش‌پردازش و تحلیل داده‌ها، فرآیند تولید داده‌های مصنوعی، مدل‌سازی بخش‌بندی خرابی‌های روسازی و ارزیابی عملکرد مدل‌های پیشنهادی مورد بررسی قرار گرفته است. این روش نوآورانه می‌تواند به عنوان رویکردی مؤثر برای بهبود دقت و کارایی سیستم‌های مدیریت روسازی مورد استفاده قرار گیرد. پس از بررسی انواع مجموعه داده‌های عمومی، یک مجموعه داده عمومی برای بخش‌بندی ترک انتخاب شد که شامل مجموعه‌ای متنوع و جامع از ترک‌های روسازی می‌باشد. سپس تصاویر این مجموعه داده تحت پیش‌پردازش قرار گرفته‌اند که شامل نرمال‌سازی، تغییر اندازه، تبدیل تصادفی افقی، و تنظیم روشنایی و کنتراست است تا تصاویر برای تحلیل آماده شوند. این فرآیند اطمینان حاصل می‌کند که تصاویر برای تحلیل مبتنی بر یادگیری عمیق مناسب بوده و می‌توانند برای آموزش مدل WGAN-GP مورد استفاده قرار گیرند.

پس از انجام پیش‌پردازش‌های مطرح شده، مدل WGAN-GP برای تولید تصاویر ترک روسازی به کار گرفته شد. سپس کیفیت این تصاویر تولیدشده ارزیابی شده تا میزان تأثیر آن‌ها در بهبود پیش‌بینی خرابی روسازی توسط مدل بخش‌بندی یونت مشخص شود. پس از ادغام تصاویر افزوده شده در مجموعه داده، مدل یونت برای ارزیابی تأثیر داده‌های افزوده شده بر عملکرد آن مورد استفاده قرار گرفته است. با آزمایش مدل یونت بر روی مجموعه داده‌هایی که شامل درصدهای مختلفی از تصاویر واقعی و افزوده شده بودند، درصد بهینه داده‌های افزوده شده مشخص شده است. در نهایت، قابلیت تعمیم مدل بخش‌بندی با آزمایش آن بر روی مجموعه داده‌های دیگر تأیید شده است.

۱-۲- آماده‌سازی و پیش‌پردازش مجموعه داده

آماده‌سازی و پیش‌پردازش مجموعه داده با پردازش تصاویر مجموعه داده عمومی کرک ۵۰۰ آغاز شده که شامل ۲۰۰۰ تصویر از ترک‌های طولی، عرضی و پوست سوسماری با حجم حدود ۳/۳۴ گیگابایت می‌باشد. این تصاویر با استفاده از یک تلفن هوشمند در جاده اصلی دانشگاه تمپل^۱ ثبت شده که در دارای ابعاد ۱۴۴۰×۲۵۶۰ و ۱۴۴۰×۲۵۶۰ پیکسل می‌باشند. برای استانداردسازی مجموعه داده و بهبود سرعت محاسبات با منابع محدود گرافیکی، تمام تصاویر به اندازه یکنواخت ۱۲۸×۱۲۸ پیکسل تغییر اندازه داده شده‌اند. این تغییر اندازه باعث ایجاد ابعاد ثابت برای تمامی ورودی‌های مدل شده که برای کاربردهای یادگیری عمیق امری حیاتی است.

در این پژوهش از مجموعه داده کرک ۵۰۰ [33,34] استفاده شده است که به طور اختصاصی برای مطالعه ترک‌های سطحی روسازی و سازه‌های بتنی و به ویژه پژوهش‌های بخش‌بندی در سطح پیکسل طراحی گردیده است. نسخه پایه این مجموعه داده شامل حدود ۵۰۰ تصویر با وضوح بالا است. برای هر تصویر اصلی، یک ماسک دودویی^۲ متناظر نیز به عنوان حقیقت مبنای^۳ (برجسب واقعی/مقدار واقعی) فراهم شده است. از آن جا که تصاویر خام دارای ابعاد بزرگی هستند، در فرآیند آماده‌سازی معمولاً به قطعات کوچک‌تر تقسیم می‌شوند و تنها قطعاتی که حاوی تراکم کافی از پیکسل‌های ترک باشند، برای آموزش مدل حفظ می‌گردند. این فرآیند فیلترینگ باعث می‌شود که مجموعه نهایی مورد استفاده، شامل چند هزار نمونه آموزشی و آزمایشی باکیفیت باشد. از نقاط قوت برجسته کرک ۵۰۰ می‌توان به وضوح بالا و دقت ماسک‌های بخش‌بندی اشاره کرد که آن را برای آموزش مدل‌های عمیقی نظیر یونت و دیپ کرک^۴ ایده‌آل می‌سازد. با این حال، محدودیت‌هایی نظیر مقیاس نسبتاً کوچک جغرافیایی برداشت داده‌ها و تنوع محدود در بافت پس‌زمینه وجود دارد که ممکن است تعمیم‌پذیری مدل به شرایط نوری و محیطی متفاوت را با چالش مواجه کند؛ چالشی که در این پژوهش با استفاده از تولید داده مصنوعی (WGAN-GP) مرتفع شده است. در شکل ۱، نمونه‌هایی از تصاویر این مجموعه داده شامل انواع ترک‌های طولی، عرضی و پوست سوسماری قابل مشاهده است.

بعد از تغییر ابعاد تصاویر، پیکسل‌های تصاویر نرمال‌سازی شده تا مقدار آن‌ها در بازه ۰ تا ۱ قرار گیرد. این نرمال‌سازی به مدل کمک می‌کند تا کارایی بهتری در آموزش داشته باشد، زیرا داده‌ها را در مقیاسی مشابه قرار داده و از مشکلاتی مانند ناپایداری گرادیان جلوگیری می‌کند و همگرایی را در طول آموزش بهبود می‌بخشد. علاوه بر اعمال تبدیل‌های تصادفی افقی و چرخش (تا ۳۰ درجه)، از تغییر رنگ برای افزایش تنوع مجموعه داده آموزشی استفاده شده است. این تکنیک با اعمال تغییرات تصادفی در روشنایی، کنتراست، اشباع رنگ و در برخی موارد تغییرات در طیف رنگی، تنوع بیشتری را در داده‌ها ایجاد می‌کند. با شبیه‌سازی تغییرات نورپردازی و ویژگی‌های بصری، تغییر رنگ به مدل کمک می‌کند تا بهتر با تغییرات دنیای واقعی در تصاویر روسازی، مانند سایه‌ها، نورپردازی نامتعادل یا درخشش سطح، سازگار شود. این تنظیمات باعث می‌شود که مدل نسبت به شرایط خاص نور یا محیط حساسیت کمتری داشته باشد و در نتیجه قابلیت تعمیم و عملکرد آن در ارزیابی بهبود یابد.

پس از اتمام پیش‌پردازش، مجموعه داده به سه بخش تقسیم شد: آموزش (۷۰٪)، آزمایش (۲۰٪) و اعتبارسنجی (۱۰٪). مجموعه آموزشی برای آموزش مدل یونت مورد استفاده قرار گرفت، در حالی که مجموعه اعتبارسنجی برای تنظیم ابرپارامترها و جلوگیری از بیش‌برازش به کار گرفته شده است. مجموعه آزمایشی نیز برای ارزیابی نهایی عملکرد مدل‌ها اختصاص یافت. با این مراحل پیش‌پردازش،

¹ Temple

² Binary Mask

³ Ground Truth

⁴ DeepCrack

مجموعه داده برای تولید تصاویر مصنوعی با استفاده از مدل WGAN-GP و همچنین برای آموزش و آزمایش مدل یونت بر روی داده‌های واقعی و مصنوعی آماده شد.



ترک طولی



ترک عرضی



ترک پوست سوسماری

شکل ۱: نمونه تصویر ترک طولی، عرضی و پوست سوسماری مجموعه داده کرک ۵۰۰

Figure 1. Sample images of longitudinal, transverse and alligator cracks from the Crack500 dataset

۲-۲- مدل مولد WGAN-GP

مدل مولد [35] WGAN-GP از دو بخش اساسی تشکیل شده است که شامل مولد و تفکیک‌کننده می‌شود. بخش مولد با استفاده از بردارهای نویز تصادفی، تصاویر مصنوعی از ترک‌های روسازی تولید می‌کند، در حالی که وظیفه بخش تفکیک‌کننده تشخیص تفاوت بین تصاویر واقعی و تولید شده است. بخش مولد به گونه‌ای آموزش داده می‌شود که تصاویری بسیار شبیه به خرابی‌های واقعی روسازی ایجاد کند، در حالی که بخش تفکیک‌کننده مهارت لازم را برای طبقه‌بندی تصاویر به عنوان واقعی یا مصنوعی به دست می‌آورد. نتیجه نهایی مدل WGAN-GP مجموعه‌ای از تصاویر مصنوعی از ترک‌های روسازی است که می‌توان از آن‌ها برای تقویت مجموعه داده‌های واقعی و آموزش مدل‌های بخش‌بندی یونت استفاده کرد. این مدل از تابع هزینه واسرشتاین همراه با جریمه گرادیان بهره می‌برد که باعث بهبود پایداری آموزش شده و تولید تصاویر متنوع و باکیفیت را تضمین می‌کند.

استفاده از مدل WGAN-GP در این مطالعه به دلیل توانایی آن در غلبه بر چالش‌های اساسی در GAN‌ها، از جمله ناپدید شدن گرادیان، فروپاشی الگو و ناپایداری در طول آموزش است. مدل WGAN-GP آموزش پایدار را فراهم کرده و تولید تصاویر مصنوعی متنوع و با کیفیت را ارائه می‌دهد. با گنجاندن منظم‌سازی جریمه گرادیان، این مدل از محدودیت پیوستگی لپشیتز^۱ استفاده می‌کند که باعث حفظ گرادیان‌های یکنواخت و کاهش نوسانات در خروجی تفکیک‌کننده می‌شود. این ویژگی باعث تولید تصاویر ترک‌های روسازی با ساختارها و الگوهای واقعی و متنوع می‌شود که به طور نزدیک با داده‌های دنیای واقعی تطابق دارند. این ویژگی‌ها مدل

^۱ Lipschitz

WGAN-GP را به انتخابی قدرتمند برای مقابله با کمبود داده‌های آموزشی در سیستم‌های ارزیابی خودکار روسازی تبدیل می‌کند و قابلیت اطمینان و عملکرد وظایف پایین‌دستی مانند بخش‌بندی ترک‌ها را بهبود می‌بخشد.

۱-۲-۲- مدل مولد

معماری مدل مولد در WGAN-GP در جدول ۱ تشریح داده شده است. مدل مولد در WGAN-GP به گونه‌ای طراحی شده است که یک بردار نهفته با اندازه ۱۵۰ را به یک تصویر خاکستری 128×128 تبدیل می‌کند. معماری این مدل با یک لایه کاملاً متصل آغاز شده که ورودی را به یک نقشه ویژگی با $8 \times 8 \times 128$ عنصر تبدیل می‌کند. پس از آن، یک دنباله از لایه‌های پیچشی معکوس (دی‌کانولوشن)^۱ قرار دارد که به تدریج وضوح فضایی را افزایش داده و عمق نقشه ویژگی را کاهش می‌دهد. هر لایه از اندازه هسته 4×4 ، گام ۲ و پدینگ^۳ یک استفاده می‌کند تا اطمینان حاصل شود که ابعاد تصویر در هر مرحله دو برابر می‌شود. لایه‌های میانه از تابع فعال‌سازی رلو^۴ برای معرفی غیرخطی بودن استفاده می‌کنند، در حالی که نرمال‌سازی دسته‌ای^۵ برای تثبیت فرآیند آموزش به کار گرفته می‌شود. لایه خروجی از تابع فعال‌سازی تانژانت هایپربولیک^۶ استفاده می‌کند که مقادیر پیکسل‌ها را به بازه $[-1, 1]$ مقیاس‌دهی می‌کند که مطابق با الزامات تابع هزینه WGAN-GP است.

جدول ۱: معماری مدل مولد

Table 1. Generative model architecture

لایه‌ها	شکل ورودی	شکل خروجی	تابع فعال‌سازی	اندازه هسته	گام	پدینگ
کاملاً متصل	(اندازه دسته، ۷، ۱۵۰)	(اندازه دسته، ۹۲، ۸)	رلو	-	-	-
پیچشی معکوس دو بعدی (لایه ۱)	(اندازه دسته، ۱۹۲، ۸)	(اندازه دسته، ۱۲۸، ۸، ۸)	رلو	4×4	۲	۱
پیچشی معکوس دو بعدی (لایه ۲)	(اندازه دسته، ۱۲۸، ۸، ۸)	(اندازه دسته، ۱۲۸، ۸، ۸)	رلو	4×4	۲	۱
پیچشی معکوس دو بعدی (لایه ۳)	(اندازه دسته، ۶۴، ۱۶، ۱۶)	(اندازه دسته، ۶۴، ۱۶، ۱۶)	رلو	4×4	۲	۱
پیچشی معکوس دو بعدی (لایه ۴)	(اندازه دسته، ۳۲، ۳۲، ۳۲)	(اندازه دسته، ۳۲، ۳۲، ۳۲)	رلو	4×4	۲	۱
پیچشی معکوس دو بعدی (لایه ۵)	(اندازه دسته، ۱۶، ۶۴، ۶۴)	(اندازه دسته، ۱۶، ۶۴، ۶۴)	رلو	4×4	۲	۱
پیچشی معکوس دو بعدی (لایه ۶)	(اندازه دسته، ۸، ۱۲۸، ۱۲۸)	(اندازه دسته، ۸، ۱۲۸، ۱۲۸)	تانژانت هایپربولیک	4×4	۲	۱

۲-۲-۲- مدل تفکیک‌کننده

مدل تفکیک‌کننده در WGAN-GP به عنوان یک مدل طبقه‌بندی دودویی عمل می‌کند که مشخص می‌کند آیا یک تصویر ورودی واقعی است یا تولید شده. این مدل تصاویر خاکستری 128×128 را به عنوان ورودی پردازش کرده و از طریق مجموعه‌ای از لایه‌های پیچشی که در جدول ۲ شرح داده شده‌اند، عبور می‌دهد. هر لایه از اندازه هسته 4×4 ، گام ۲ و پدینگ ۱ استفاده می‌کند که باعث می‌شود ابعاد فضایی کاهش یابد و در عین حال تعداد فیلترها افزایش یابد.

معماری مدل با ورودی با شکل $(1, 128, 128)$ شروع می‌شود که متناظر با یک کانال خاکستری از تصویر است. لایه‌های پیچشی از تابع فعال‌سازی لیکی رلو^۸ استفاده می‌کنند که به شبکه این امکان را می‌دهد که ویژگی‌ها را از گرادین‌های مثبت و منفی یاد بگیرد و تشخیص ویژگی‌ها را در تصاویر پیچیده بهبود بخشد. هر لایه (به جز لایه نهایی) شامل نرمال‌سازی دسته‌ای است تا یادگیری را تثبیت کرده و از فروپاشی الگو جلوگیری کند. با پیشرفت داده‌ها از طریق شبکه، تعداد فیلترها در هر مرحله دو برابر می‌شود، از ۶۴ در لایه اول به ۱۰۲۴ در لایه قبل از آخر، که به تفکیک‌کننده این امکان را می‌دهد که ویژگی‌های پیچیده‌تر تصویر را شبیه‌سازی کند. لایه نهایی با

¹ Deconvolution

² Stride

³ Padding

⁴ ReLU

⁵ Batch normalization

⁶ Tanh

⁷ Batch size

⁸ LeakyReLU

استفاده از تابع فعال سازی سیگموئید خروجی با اندازه (۱، ۱، ۱) تولید می کند که یک مقدار احتمال را نشان می دهد و مشخص می کند که آیا ورودی واقعی است یا مصنوعی.

جدول ۲: معماری مدل تفکیک کننده

Table 2. Discriminator model architecture

لایه ها	شکل ورودی	شکل خروجی	تابع فعال سازی	اندازه هسته	گام	پدینگ
پیچشی معکوس دو بعدی (لایه ۱)	(اندازه دسته، ۱، ۱۲۸، ۱۲۸)	(سایز دسته، ۶۴، ۶۴، ۶۴)	لیکی رلو	۴×۴	۲	۱
پیچشی معکوس دو بعدی (لایه ۲)	(اندازه دسته، ۶۴، ۶۴، ۶۴)	(سایز دسته، ۱۲۸، ۳۲، ۳۲)	لیکی رلو	۴×۴	۲	۱
پیچشی معکوس دو بعدی (لایه ۳)	(اندازه دسته، ۱۲۸، ۳۲، ۳۲)	(سایز دسته، ۲۵۶، ۱۶، ۱۶)	لیکی رلو	۴×۴	۲	۱
پیچشی معکوس دو بعدی (لایه ۴)	(اندازه دسته، ۲۵۶، ۱۶، ۱۶)	(سایز دسته، ۵۱۲، ۸، ۸)	لیکی رلو	۴×۴	۲	۱
پیچشی معکوس دو بعدی (لایه ۵)	(اندازه دسته، ۵۱۲، ۸، ۸)	(سایز دسته، ۱۰۲۴، ۴، ۴)	لیکی رلو	۴×۴	۲	۱
پیچشی معکوس دو بعدی (لایه ۶)	(اندازه دسته، ۱۰۲۴، ۴، ۴)	(سایز دسته، ۱، ۱، ۱)	تانژانت هایپربولیک	۴×۴	۱	۰

۲-۲-۳- جریمه گرادیان

جریمه گرادیان یک عبارت منظم سازی در WGAN-GP است که محدودیت پیوستگی لپشیتز را اعمال می کند که برای آموزش پایدار ضروری است. در این زمینه، آموزش پایدار به مدل این امکان را می دهد که به طور مؤثر یاد بگیرد بدون اینکه با موانعی مانند فروپاشی حالت یا حذف گرادیان^۱ مواجه شود که می توانند فرآیند آموزش را مختل کرده و به عملکرد ضعیف منجر شوند. این جریمه همچنین اطمینان می دهد که خروجی تفکیک کننده با تغییرات کوچک در ورودی به طور سریع تغییر نمی کند. این محدودیت به حفظ یک فرآیند یادگیری روان و پیش بینی پذیر کمک می کند. به طور خاص، این جریمه نیاز دارد که نرمال گرادیان تفکیک کننده نسبت به داده های ورودی برابر با یک باشد. اگر از یک انحراف کند، مدل می تواند ناپایدار شود، به این معنی که ممکن است نتواند همگرا شود یا تصاویر مصنوعی با کیفیت ضعیف تولید کند. جریمه گرادیان به حفظ این پایداری کمک می کند و اطمینان می دهد که نرمال گرادیان به یک نزدیک بماند.

برای محاسبه جریمه گرادیان، ابتدا نمونه های واقعی و جعلی با ایجاد یک جمع وزنی با استفاده از وزن های درون یابی (آلفا) که از صفر تا یک متغیر هستند، درهم آمیخته می شوند. سپس این نمونه های درون یابی شده از طریق تفکیک کننده عبور می کنند. گرادیان های خروجی تفکیک کننده نسبت به این نمونه های درون یابی محاسبه شده و نرمال آن ها با یک که مقدار مورد نظر برای برآوردن شرایط لپشیتز است، مقایسه می شود. عبارت جریمه تفاوت مربعی بین نرمال گرادیان و یک است که بر روی کل دسته میانگین گرفته می شود. این جریمه اطمینان می دهد که تفکیک کننده به خوبی عمل کرده و به آموزش پایدار کمک کند.

۲-۲-۴- تنظیم دقیق ابر پارامترها

تنظیم دقیق ابر پارامترهای مدل WGAN-GP با استفاده از داده های آماده شده انجام شده است. مدل های تولید کننده و تفکیک کننده به طور متناوب با استفاده از ابر پارامترهای خاص آموزش داده شدند تا عملکرد آن ها بهینه شود. ابعاد پنهان به اندازه ۱۵۰ تنظیم شد که اندازه ورودی بردار نویز تصادفی به تولید کننده را مشخص می کند. نرخ یادگیری برای تولید کننده به ۰/۰۰۲ تنظیم شد، در حالی که نرخ یادگیری برای تفکیک کننده ۰/۰۰۱ در نظر گرفته شده است. این مقادیر به منظور متعادل کردن سرعت همگرایی و پایداری آموزش انتخاب شدند.

ضریب جریمه گرادیان مقدار ۲۰ در نظر گرفته شده که اطمینان حاصل شود محدودیت پیوستگی لپشیتز به طور مؤثر اعمال می شود، که منجر به حفظ پایداری آموزش و جلوگیری از مشکلاتی مانند فروپاشی حالت یا حذف گرادیان می شود. مدل برای ۲۰۰ تکرار آموزش داده شده که بهترین نتایج را بر اساس کیفیت تصاویر تولیدی و پایداری فرآیند آموزش به دست آمده است. در طول آموزش، مدل تولید کننده تلاش کرده تا تصاویر مصنوعی واقعی تولید کند، در حالی که مدل تفکیک کننده برای تمایز بین تصاویر واقعی و مصنوعی

¹ Vanishing gradient

در حال آموزش است. فرآیند آموزش متناوب شامل به‌روزرسانی مدل‌های تولیدکننده و تفکیک‌کننده به طور متناوب بوده، به‌طوری‌که تفکیک‌کننده به طور مکرر به‌روزرسانی شده تا اطمینان حاصل شود که یک رقیب قوی برای مدل تولیدکننده باقی بماند. ابرپارامترهای اضافی شامل اندازه دسته بوده که به ۶۴ تنظیم شد تا آموزش کارآمد باشد و در عین حال تعادلی بین بار محاسباتی و عملکرد مدل حفظ شود. الگوریتم بهینه‌ساز استفاده شده برای تولیدکننده و تفکیک‌کننده آدام^۱ بوده، با بتای یک تنظیم‌شده بر روی ۰/۵ و بتای دو تنظیم شده بر روی ۰/۹ می‌باشد. این مقادیر برای تثبیت فرآیند آموزش و بهبود همگرایی انتخاب شده‌اند. خلاصه‌ای از ابرپارامترهایی که برای تنظیم دقیق مدل WGAN-GP استفاده شده‌اند در جدول ۳ آورده شده است.

جدول ۳: ابرپارامترهای استفاده شده برای تنظیم مدل WGAN-GP

Table 3. Hyperparameters to fine-tune the WGAN-GP model

مقدار	ابرپارامتر
۱۵۰	ابعاد پنهان
۰/۰۰۰۲	نرخ یادگیری (تولیدکننده)
۰/۰۰۰۱	نرخ یادگیری (تفکیک‌کننده)
۲۰	ضریب جریمه گرادیان
۲۰۰	تعداد تکرارها
۶۴	اندازه دسته
آدام	بهینه‌ساز
۰/۵	بتا یک
۰/۹	بتا دو

در ادامه این مراحل، ابرپارامترهای مدل WGAN-GP به طور دقیق تنظیم شد تا تصاویر مصنوعی با کیفیت بالا تولید کند که می‌تواند برای افزایش داده‌های اصلی و بهبود عملکرد مدل یونت در وظایف بخش‌بندی ترک‌های آسفالت استفاده شود.

۵-۲-۲- ارزیابی عملکرد

مدل مولد WGAN-GP با استفاده از چهار معیار رایج ارزیابی می‌شود که شامل: (۱) خطای میانگین مربعات^۲، (۲) شاخص شباهت ساختاری^۳، (۳) ضریب دایس^۴ و (۴) نسبت بیشینه سیگنال به نویز^۵ می‌باشد. خطای میانگین مربعات، میانگین تفاوت‌های مربعات بین مقادیر پیکسل‌های تصاویر واقعی و تولیدی را اندازه‌گیری می‌کند. خطای میانگین مربعات کمتر به این معناست که تصاویر تولیدی به تصاویر واقعی نزدیک‌تر هستند که عملکرد بهتر مدل را نشان می‌دهد. این معیار به تفاوت‌های بزرگ حساس است و اشتباهات بزرگ‌تر را بیشتر از اشتباهات کوچک مجازات می‌کند که می‌تواند بسته به کاربرد آن، به عنوان مزایا یا معایب آن به شمار آید. تفاوت‌ها بر اساس مقادیر پیکسل‌های تصاویر و نه تنها بر اساس تعداد پیکسل‌های مختلف محاسبه می‌شود.

شاخص شباهت ساختاری یک معیار ادراکی است که شباهت ساختاری بین دو تصویر را مقایسه می‌کند و در آن روشی، کنتراست، و بافت مد نظر قرار می‌گیرد. مقادیر شاخص شباهت ساختاری از ۱- تا ۱ متغیر است که ۱ نشان‌دهنده تصاویر مشابه و ۱- نشان‌دهنده عدم شباهت است. امتیازهای بالاتر شاخص شباهت ساختاری نشان‌دهنده کیفیت بصری بهتر هستند و به دلیل این که با ادراک انسانی بیشتر هم‌راستا است، از شاخص شباهت ساختاری پیشی می‌گیرد. شاخص شباهت ساختاری ارزیابی می‌کند که ساختارهای تصاویر تولیدی تا چه حد مشابه ساختارهای تصاویر واقعی هستند و تمرکز آن بر حفظ لبه‌ها و بافت‌ها است. شباهت بافت با مقایسه الگوها و جزئیات تصاویر ارزیابی می‌شود. ضریب دایس معیار آماری بوده که برای اندازه‌گیری شباهت بین دو نمونه استفاده می‌شود و اغلب در

¹ Adam

² Mean Squared Error (MSE)

³ Structural Similarity Index Measure (SSIM)

⁴ Dice Coefficient (DC)

⁵ Peak Signal-to-Noise Ratio (PSNR)

بخش‌بندی تصویر کاربرد دارد. این معیار به‌ویژه برای ارزیابی تصاویر باینری، مانند تصاویر بخش‌بندی شده از ترک‌های آسفالت مفید است. ضریب دایس از ۰ تا ۱ متغیر است که ۱ نشان‌دهنده هم‌پوشانی کامل بین ماسک‌های پیش‌بینی شده و واقعی است و ۰ نشان‌دهنده عدم هم‌پوشانی است. این معیار به تعداد مثبت‌های واقعی (پیکسل‌های ترک شناسایی شده به‌درستی) و اندازه نواحی مقایسه شده (مقدار ترک‌ها) حساس است. نسبت بیشینه سیگنال به نویز یک معیار رایج برای ارزیابی کیفیت تصویر در زمینه فشرده‌سازی و بازسازی است. این نسبت رابطه بین حداکثر مقدار پیکسل و میزان نویز در تصویر را با استفاده از خطای میانگین مربعات بیان می‌کند. مقادیر بالاتر نسبت بیشینه سیگنال به نویز نشان‌دهنده نویز کمتر در تصویر است که معمولاً مقادیر آن بین ۲۰ دسی‌بل تا ۴۰ دسی‌بل برای تصاویر با کیفیت خوب متغیر است. این معیار ارزیابی جامعی از توانایی مدل WGAN-GP در تولید تصاویر واقعی و با کیفیت بالا از خرابی‌های آسفالت ارائه می‌دهد و سطح نویز و اعوجاج در تصاویر تولیدی را اندازه‌گیری می‌کند.

۳-۲- مدل بخش‌بندی ترک‌های آسفالت

مدل بخش‌بندی [36,37] ترک‌های آسفالت استفاده شده در این مطالعه شامل افزایش مجموعه داده عمومی کرک ۵۰۰ با افزودن تصاویری است که توسط مدل WGAN-GP تولید شده‌اند و در مقادیر مختلف ۵۰، ۱۵۰، ۲۵۰، ۱۰۰۰ و ۵۰۰۰ تصویر به مجموعه داده اضافه شدند. هدف از این افزایش داده‌ها ارزیابی تأثیر افزودن داده‌های مصنوعی بر عملکرد مدل یونت و تعیین درصد بهینه داده‌های افزوده‌شده برای بهبود عملکرد مدل یونت بود. به طور خاص، مدل مورد استفاده برای بخش‌بندی مبتنی بر معماری یونت در پایتورچ^۱ بود که از کدگذاری کننده رزنت-۳۴ بهره می‌برد [38]. این معماری برای وظایف بخش‌بندی، مانند شناسایی ترک‌های آسفالت، مناسب است زیرا ویژگی‌های سلسله‌مراتبی را به طور کارآمد از طریق ساختار کدگذار-رمزگذار^۲ استخراج می‌کند.

۳-۱-۲- تنظیم ابرپارامترها

تنظیم دقیق ابرپارامترهای مدل یونت برای بهینه‌سازی عملکرد آن در بخش‌بندی ترک‌های آسفالت بسیار مهم می‌باشد. الگوریتم بهینه‌ساز که برای آموزش استفاده شده آدام بوده و نرخ یادگیری آن به ۰/۰۰۰۱ تنظیم گردیده است. این نرخ یادگیری به‌گونه‌ای انتخاب شده که تعادلی میان سرعت همگرایی و پایداری فرآیند آموزش برقرار کند. مدل برای ۵۰ تکرار آموزش داده شده است؛ زیرا این تعداد تکرار منجر به همگرایی شد، به‌طوری‌که بهترین نتایج بدون بیش‌برازش به دست آمد. اندازه دسته به ۱۶ تنظیم گردید که این امر آموزش کارآمد را در حالی که تعادلی میان بار محاسباتی و عملکرد مدل حفظ می‌کند، امکان‌پذیر ساخت. با تنظیم دقیق این ابرپارامترها، مدل یونت قادر شد به طور مؤثر از تصاویر اصلی کرک ۵۰۰ و مجموعه‌های داده افزوده شده حاوی تصاویر مصنوعی تولیدشده توسط مدل WGAN-GP یاد بگیرد. این فرآیند توانایی مدل را در بخش‌بندی دقیق ترک‌های آسفالت تقویت کرده و با استفاده از ترکیب نقاط قوت داده‌های واقعی و مصنوعی، دقت و توانایی‌های تعمیم‌پذیری آن را بهبود بخشیده است.

۳-۲-۲- ارزیابی عملکرد

برای ارزیابی عملکرد بخش‌بندی مدل یونت، چندین معیار کلیدی استفاده شد که شامل موارد زیر است: (۱) خطای آموزش، اعتبارسنجی و آزمایش، (۲) ضریب دایس و (۳) اشتراک برروی اجتماع^۴. معیار اول، خطای یک معیار برای تفاوت میان خروجی پیش‌بینی‌شده مدل و برچسب‌های واقعی در طول آموزش است. مقادیر پایین‌تر خطا نشان‌دهنده این است که پیش‌بینی‌های مدل به‌طور دقیق با بخش‌بندی واقعی هم‌راستا هستند. برای مجموعه‌های آموزش، اعتبارسنجی و آزمایش، خطا، بینشی درباره توانایی تعمیم مدل ارائه می‌دهد. دوم، ضریب دایس میزان هم‌پوشانی بین ماسک‌های بخش‌بندی پیش‌بینی‌شده و واقعی را اندازه‌گیری می‌کند. این مقدار به‌صورت دو برابر مساحت هم‌پوشانی تقسیم بر تعداد کل پیکسل‌ها در هر دو ماسک محاسبه می‌شود. ضریب دایس بالاتر که به یک نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر بخش‌بندی است. سوم، اشتراک برروی اجتماع که همچنین به‌عنوان شاخص جاکارد شناخته می‌شود، نسبت تقاطع ماسک‌های پیش‌بینی‌شده و واقعی به اتحاد آن‌ها را اندازه‌گیری می‌کند. این معیار درک شهودی از دقت بخش‌بندی

¹ PyTorch

² ResNet 34

³ Encoder-Decoder

⁴ Intersection over Union (IoU)

ارائه می‌دهد، به‌طوری‌که اشتراک بر روی اجتماع بالاتر دقت بیشتری در بخش‌بندی پیش‌بینی‌شده را نشان می‌دهد. هم ضریب دایس و هم اشتراک بر روی اجتماع برای ارزیابی کیفیت مدل‌های بخش‌بندی حیاتی هستند، به‌ویژه در وظایفی مانند تشخیص خرابی‌های آسفالت که در آن دقت در ترسیم مرزها بسیار مهم است.

۳- نتایج مدل WGAN-GP و مدل یونت


این بخش تأثیر افزودن تصاویر تولید شده توسط مدل به مجموعه داده کرک ۵۰۰ را ارائه می‌دهد. تصاویر تولید شده به صورت افزایشی با درصدهای ۲۰، ۶۰، ۱۰۰، ۴۰۰ و ۲۰۰۰ نسبت به اندازه اولیه مجموعه داده به آن اضافه شدند. عملکرد مدل یونت ارزیابی شد تا تأثیر استفاده از تصاویر تولید شده بر بهبود عملکرد مدل و شناسایی ترکیب بهینه مجموعه داده برای بهبود نتایج بخش‌بندی بررسی شود. علاوه بر این، مدل‌ها با استفاده از پلتفرم ابری کگل^۱ توسعه، آموزش و ارزیابی شدند که منابع محاسباتی قدرتمندی برای مدیریت مجموعه داده‌های بزرگ و وظایف پیچیده یادگیری عمیق فراهم می‌کند. مدل یونت با استفاده از تنسورفلو پیاده‌سازی شد، در حالی که مدل WGAN-GP با پایتورچ توسعه یافت. محیط کگل ۵۷/۶ گیگابایت فضای دیسک، ۲۹ گیگابایت حافظه رم و یک گرافیک انویدیا تسلا پی ۱۰۰ با ۱۶ گیگابایت حافظه را ارائه می‌دهد که تضمین‌کننده آموزش کارآمد و مدیریت وظایف محاسباتی پیچیده است. این تنظیمات امکان پردازش سریع‌تر تصاویر با وضوح بالا و محاسبات یادگیری عمیق برای بخش‌بندی و تولید تصاویر را فراهم کرد. در ادامه، توانایی مدل WGAN-GP در تولید تصاویر مصنوعی که شبیه مجموعه داده واقعی بوده و تأثیر آن‌ها بر عملکرد مدل بخش‌بندی بررسی شده است.

۳-۱- تولید تصویر خرابی روسازی با مدل WGAN-GP

بعد از تنظیم دقیق ابرپارامترهای مدل WGAN-GP، از آن برای تولید تصاویر مصنوعی ترک‌های آسفالت استفاده شده است. شکل ۲ تصاویر مختلفی از مراحل تولید تصویر ترک‌های آسفالت مصنوعی توسط مدل WGAN-GP در تکرارهای آموزشی ۱، ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ را نشان می‌دهد. در تکرار ۵۰، تصاویر عناصر ساختاری پایه‌ای را نشان می‌دهند اما ویژگی‌های دقیق‌تری ندارند که نشان‌دهنده مرحله اولیه یادگیری است. تا تکرار ۱۵۰، تصاویر وضوح بهتری پیدا کرده و الگوهای تعریف‌شده‌تری نشان می‌دهند که پیشرفت چشمگیری در آموزش را نشان می‌دهد. در تکرار ۲۰۰، مدل تصاویر با وضوح بالا و ویژگی‌های واقعی تولید می‌کند که به طور دقیق ترک‌های آسفالت واقعی را شبیه‌سازی می‌کند و توانایی مدل در گرفتن جزئیات دقیق را با آموزش طولانی‌مدت نشان می‌دهد. برای ارزیابی عملکرد مدل WGAN-GP، از معیارهای میانگین مربعات، شاخص شباهت ساختاری، ضریب دایس و نسبت بیشینه سیگنال به نویز استفاده شده است. مقادیر گزارش‌شده، شامل خطای میانگین مربعات، شاخص شباهت ساختاری، ضریب دایس و نسبت بیشینه سیگنال به نویز، نتیجه مقایسه کمی بین تصاویر واقعی ترک‌های آسفالت و تصاویر مصنوعی تولیدشده پس از ۲۰۰ تکرار آموزش هستند. مقدار خطای میانگین مربعات برابر با ۰/۰۴ نشان می‌دهد که تفاوت‌های سطح پیکسل بین تصاویر واقعی و تولیدی کم است که نشان‌دهنده تقریب نزدیک داده‌های واقعی توسط مدل مولد است. شاخص شباهت ساختاری با مقدار ۰/۸۹ نشان‌دهنده شباهت ساختاری بالاست که از لحاظ روشنایی، کنتراست و بافت، نشان می‌دهد که تصاویر تولیدی به‌خوبی ساختار کلی ترک‌های آسفالت را به تصویر کشیده‌اند. ضریب دایس برابر با مقدار ۰/۹۰ تأکید بر هم‌پوشانی بالای ویژگی‌های کلیدی، به‌ویژه ترک‌ها دارد که توانایی مدل در بازسازی ویژگی‌های بحرانی آسفالت را نشان می‌دهد. در نهایت، نسبت بیشینه سیگنال به نویز با مقدار برابر ۳۱ نشان‌دهنده کیفیت خوب تصاویر تولیدی است، با نویز یا اعوجاجات جزئی که در محدوده مناسبی برای این کاربرد قرار دارند.

¹ Kaggle

² NVIDIA Tesla P100



شکل ۲: تولید تصویر خرابی‌ها با مدل WGAN-GP در تکرارهای ۱، ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰
 Figure 2. Generating the image of distresses with WGAN-GP model in 1, 50, 100, 150, and 200 iterations

۳-۲- عملکرد مدل بخش‌بندی یونت

در این بخش عملکرد مدل یونت را در بخش‌بندی ترک‌های آسفالت با استفاده از مجموعه داده اصلی کرک ۵۰۰ و تصاویر افزوده شده با درصدهای مختلف از تصاویر مصنوعی تولید شده توسط مدل WGAN-GP ارزیابی شده است. جدول ۴ خلاصه‌ای از میزان خطا، ضریب دایس و اشتراک بر روی اجتماع برای مدل یونت که با مجموعه داده اصلی کرک ۵۰۰ و پنج مجموعه داده دیگر شامل تصاویر افزوده شده آموزش دیده است را نشان می‌دهد. به عبارت دیگر، عملکرد مدل یونت که با مجموعه داده اصلی آموزش دیده با تعداد مختلفی از تصاویر افزوده شده به مجموعه داده اصلی مقایسه می‌شود.

برای مدل پایه با ۲۵۰ تصویر اصلی، نتایج اعتبارسنجی نشان می‌دهد که مقدار خطا برابر 0.32 ، ضریب دایس برابر 0.929 و اشتراک بر روی اجتماع برابر 0.868 است. افزودن ۵۰ (یعنی ۲۰ درصد) تصویر افزوده منجر به بهبود جزئی در مقادیر ضریب دایس و اشتراک بر روی اجتماع شده که باعث کاهش خطا به مقدار 0.31 ، افزایش ضرایب دایس برابر 0.934 و اشتراک بر روی اجتماع برابر 0.877 شد. افزودن ۱۵۰ (یعنی ۶۰ درصد) و ۲۵۰ (یعنی ۱۰۰ درصد) تصویر افزوده باعث افزایش بیشتر این مقادیر شد. بررسی دقیق‌تر با افزودن ۵۰۰ تصویر (۲۰۰ درصد) نشان داد که مدل همچنان ظرفیت یادگیری بالایی دارد و به ضریب دایس 0.958 و مقدار اشتراک بر روی اجتماع برابر 0.915 دست یافت. علاوه بر این، زمانی که ۱۰۰۰ (یعنی ۴۰۰ درصد) تصویر افزوده اضافه شد، مدل بهترین عملکرد خود با کاهش چشمگیر خطا به مقدار 0.10 ، افزایش ضرایب دایس برابر 0.961 و مقدار اشتراک بر روی اجتماع برابر 0.925 به دست آورد. پس از این نقطه بهینه، با افزودن ۲۰۰۰ تصویر (۸۰۰ درصد)، اگر چه عملکرد همچنان تا حدودی پایدار ماند (ضریب دایس برابر


۰/۹۵۶ و مقدار اشتراک بر روی اجتماع برابر ۰/۹۱۸)، اما نشانه‌هایی از توقف روند صعودی مشاهده شد. اما با افزایش تعداد تصاویر افزوده به ۵۰۰۰ (یعنی ۲۰۰۰ درصد)، عملکرد مدل کاهش بیشتری یافت، ضریب دایس برابر ۰/۹۵ و مقدار اشتراک بر روی اجتماع برابر ۰/۹۱۰ کاهش و مقدار خطا به ۰/۰۲۰ افزایش یافتند. این نشان می‌دهد که با افزایش تعداد تصاویر افزوده به بیش از حد بهینه، بهبود عملکرد مدل کاهش یافته و ممکن است حتی منجر به بیش‌برازش مدل شود.

شکل‌های ۳ و ۴ روند مقادیر مدل یونت را در درصدهای مختلف تصاویر افزوده شده نشان می‌دهند، در حالی که جدول ۴ مقادیر دقیق هر معیار را برای هر وضعیت فراهم می‌کند. همان‌طور که در این شکل‌ها و جدول نشان داده شده، بهترین عملکرد با ۱۰۰۰ تصویر افزوده به دست آمده که نشان می‌دهد مدل یونت بهترین عملکرد را با مجموعه داده ای که ۴۰۰ درصد افزایش یافته بود، داشته است. نتایج همچنین اهمیت داده‌های افزوده شده برای بهبود دقت و تعمیم مدل را تأکید می‌کنند. درصدهای دیگر بین ۱۰۰۰ و ۵۰۰۰ نیز آزمایش شدند، اما تغییرات در عملکرد قابل توجه نبوده و نشان می‌دهد که داده‌های بیشتر از این تعداد تصاویر به‌طور معناداری عملکرد مدل را بهبود نمی‌بخشند. بنابراین، مدل یونت با ۱۰۰۰ تصویر افزوده به عنوان مدل بهینه معرفی شده است.


جدول ۴: عملکرد مدل یونت با درصدهای مختلف داده‌های افزایشی اضافه شده به مجموعه داده کرک ۵۰۰ - مجموعه آزمایش

Table 4. U-Net model performance with different percentages of incremental data added to the Crack500 dataset (test data)

پارامتر	مجموعه داده							تصاویر اضافه شده
	اصلی	۲۵۰ (۰٪)	۵۰ (۰.۲۰٪)	۱۵۰ (۰.۶۰٪)	۲۵۰ (۱.۰۰٪)	۵۰۰ (۲.۰۰٪)	۱۰۰۰ (۴.۰۰٪)	
مقدار خطا	۰/۳۲۰	۰/۰۳۱	۰/۰۲۵	۰/۰۲۱	۰/۰۱۵	۰/۰۱۰	۰/۰۱۴	۰/۰۲۰
ضریب دایس	۰/۹۲۹	۰/۹۳۴	۰/۹۴۸	۰/۹۵۰	۰/۹۵۸	۰/۹۶۱	۰/۹۵۶	۰/۹۵۰
اشتراک بر روی اجتماع	۰/۸۶۸	۰/۸۷۷	۰/۸۹۹	۰/۹۰۵	۰/۹۱۵	۰/۹۲۵	۰/۹۱۸	۰/۹۱۰



شکل ۳: تغییرات در میزان خطا با افزایش تعداد تصاویر
Figure 3. Changes in error rate with increased images




شکل ۴: تغییرات در ضریب دایس و اشتراک بر روی اجتماع با افزایش تعداد تصاویر
Figure 4. Changes in Dice coefficient and intersection over union with increased images

انتخاب ۱۰۰۰ تصویر مصنوعی به عنوان اندازه بهینه افزایشی بر اساس آزمایش‌های سیستماتیک انجام شده است که توازن بین تعمیم مدل و بیش‌برازش را حفظ می‌کند. این روش تجربی، رابطه عملی بین تنوع داده‌ها و عملکرد مدل را برجسته می‌کند. پس از این اندازه، بازدهی نزولی و احتمالاً تمایل به الگوهای مصنوعی مشاهده شد که نشان‌دهنده اهمیت افزایشی کنترل‌شده برای دستیابی به تفکیک عمومی است.

در شکل‌های ۵ تا ۷، مدل یونت عملکرد متعادلی را در مجموعه داده اصلی برای هر دو مجموعه آموزش و اعتبارسنجی نشان می‌دهد که این تعادل از طریق مقادیر نزدیک سنج‌های مختلف مانند خطای آموزش و اعتبارسنجی، ضریب دایس و اشتراک بر روی اجتماع قابل مشاهده است. این شکل‌ها روند تغییرات سنج‌ها را در طول ۵۰ تکرار آموزشی برای مجموعه داده اصلی به تصویر می‌کشند، جایی که مقدار خطای آموزش در پایان تکرارها به ۰/۰۳۲ و خطای اعتبارسنجی به ۰/۰۳۵ می‌رسد و این مقادیر نزدیک به یکدیگر بیانگر یادگیری مؤثر مدل بدون نشانه‌ای از بیش‌برازش است. همچنین ضریب دایس در مجموعه آموزش برابر با ۰/۹۳۷ و در اعتبارسنجی برابر با ۰/۹۳۶ بوده که نشان‌دهنده هم‌پوشانی بالای نواحی پیش‌بینی‌شده با نواحی واقعی است. مقادیر اشتراک بر روی اجتماع نیز در آموزش ۰/۸۷۷ و در اعتبارسنجی ۰/۸۹۱ می‌باشد که تعمیم‌پذیری مدل را در مجموعه داده اصلی تأیید می‌کند و نشان می‌دهد که مدل به خوبی الگوهای پایه‌ای ترک‌های آسفالت را بدون وابستگی بیش از حد به داده‌های آموزشی فرا گرفته است.


شکل‌های ۸ تا ۱۰ عملکرد مدل یونت را بر روی مجموعه داده بهینه شده (که با افزودن ۱۰۰۰ تصویر افزایشی به مجموعه داده اصلی) در مجموعه‌های آموزش و اعتبارسنجی به نمایش می‌گذارد و بهبود قابل توجهی نسبت به مجموعه داده اصلی را برجسته می‌کند. این شکل‌ها روند سنج‌ها را در طول ۵۰ تکرار آموزشی برای مجموعه بهینه ترسیم می‌کنند، جایی که خطای آموزش به ۰/۰۲۹ و خطای اعتبارسنجی به ۰/۰۳۱ کاهش یافته که نزدیکی این مقادیر حاکی از همگرایی سریع‌تر و یادگیری پایدارتر مدل است. ضریب دایس در مجموعه آموزش برابر با ۰/۹۶۷ و در اعتبارسنجی برابر با ۰/۹۶۵ بوده که افزایش هم‌پوشانی را نسبت به مجموعه اصلی نشان می‌دهد. همچنین مقادیر اشتراک بر روی اجتماع در آموزش ۰/۹۳۱ و در اعتبارسنجی ۰/۹۲۷ می‌باشد که بهبود تعمیم‌پذیری را نشان می‌دهد و بیانگر آن است که افزودن تصاویر افزایشی، مدل را در برابر تنوعات بیشتر مقاوم‌تر کرده و الگوهای پیچیده‌تر ترک‌ها را بهتر شبیه‌سازی می‌نماید.

مقایسه عملکرد مدل بر روی مجموعه داده‌های اصلی و بهینه‌شده بر اساس شکل‌های ۵ تا ۱۰ حاکی از آن است که مدل بهینه هم‌راستایی بهتری بین منحنی‌های آموزش و اعتبارسنجی نشان می‌دهد، سریع‌تر همگرا می‌شود و با کاهش بیش‌برازش، دقت کلی را افزایش می‌دهد. انتخاب ۵۰ تکرار بر اساس آزمایش‌های تجربی بهینه بوده، زیرا تکرارهای کمتر به کم‌برازش و تکرارهای بیشتر به بیش‌برازش منجر می‌شد که در آن مدل بر داده‌های آموزشی بیش از حد تطبیق می‌یافت اما در اعتبارسنجی ضعیف عمل می‌کرد.




شکل ۵: نمودار خطای آموزش، اعتبارسنجی برای مدل یونت برای مجموعه داده اصلی

Figure 5. Training and validation error plot for the U-Net model - original dataset




شکل ۶: نمودار اشتراک بر روی اجتماع برای مدل یونت برای مجموعه داده اصلی

Figure 6. Intersection over union plot for the U-Net model - original dataset




شکل ۷: نمودار ضریب دایس برای مجموعه داده اصلی

Figure 7. Dice coefficient plot - original dataset




شکل ۸: نمودار خطای آموزش، اعتبارسنجی برای مدل یونت برای مدل بهینه

Figure 8. Training and validation error plot for the U-Net model - optimum model



شکل ۹: نمودار اشتراک بر روی اجتماع برای مدل یونت برای مدل بهینه


Figure 9. Intersection over union plot for the U-Net model - optimum model



شکل ۱۰: نمودار ضریب دایس برای مدل یونت برای مدل بهینه

Figure 10. Dice coefficient plot - optimum model

شکل ۱۱ نمونه‌هایی از تصاویر مدل بهینه یونت را نشان می‌دهد. این شکل شامل تصویر ورودی (اصلی) و تصویر پیش‌بینی شده‌ای بوده که توسط مدل تولید شده است. تصویر ورودی نشان دهنده سطح آسفالت با ترک‌های قابل مشاهده است. تصویر پیش‌بینی شده، خروجی مدل را نشان می‌دهد که هدف آن شناسایی و بخش‌بندی ترک است. این مقایسه امکان بررسی بصری توانایی مدل در بخش‌بندی دقیق ترک‌ها را فراهم می‌آورد. هر چه تصویر پیش‌بینی شده بیشتر مشابه تصویر ورودی باشد، نشان‌دهنده یادگیری بهتر مدل در شناسایی ترک است. با توجه به بهبود عملکرد مدل بهینه، انتظار می‌رود که بخش‌بندی پیش‌بینی شده با تصویر ورودی به طور نزدیکی هم‌راستا باشد، که نشان‌دهنده این است که بخش‌های پیش‌بینی شده توسط مدل همانند تصویر ورودی هستند.



شکل ۱۱: نتایج بخش‌بندی برای مدل یونت با ۱۰۰۰ تصویر مصنوعی اضافی
Figure 11. Segmentation outcomes for the U-Net model with 1000 additional synthetic images

۳-۳- ارزیابی قابلیت تعمیم‌دهی مدل بخش‌بندی

در این بخش قابلیت تعمیم‌دهی مدل بخش‌بندی بهینه یونت که با ۱۰۰۰ تصویر افزوده آموزش داده شده، ارزیابی شده است. معیارهای ارزیابی شامل خطا، ضرایب دایس و اشتراک بر روی اجتماع می‌باشد. این معیارها بینش‌هایی را در مورد توانایی مدل در بخش‌بندی دقیق ترک‌های آسفالت در شرایط و انواع مختلف ترک‌ها ارائه می‌دهند. برای ارزیابی تعمیم مدل، آن را بر روی چهار مجموعه داده دنیای واقعی شامل سی‌اف‌دی^۱، کرک‌تری^۲، دیپ‌کرک^۳ و گپس^۴ ۳۸۴ آزمایش شده است. این مجموعه داده‌ها به دلیل تنوع خود در انواع خرابی‌ها و شرایط تصویربرداری انتخاب شدند. مجموعه داده سی‌اف‌دی شامل تصاویری با طیف وسیعی از انواع ترک‌ها است. کرک‌تری ۲۰۰ بر الگوهای ترک درختی متمرکز است که پیچیده‌تر و بخش‌بندی آن چالش‌برانگیزتر است. دیپ‌کرک تعداد زیادی تصویر با الگوهای ترک و شدت‌های مختلف دارد. گپس ۳۸۴ نیز شامل تصاویری با وضوح بالا از ترک‌ها است. نتایج ارزیابی قابلیت تعمیم

¹ CFD

² Cracktree200

³ DeepCrack

⁴ GAPS384

مدل بهینه در جدول ۵ خلاصه شده است. این جدول نشان‌دهنده مقادیر خطا، ضرایب دایس و اشتراک بر روی اجتماع برای هر مجموعه داده است و عملکرد مدل تحت شرایط مختلف آزمایشی را ارائه می‌دهد.

جدول ۵: عملکرد مدل بخش‌بندی بهینه بر روی مجموعه‌های داده مختلف
Table 5. Performance of the optimal segmentation model on different datasets

مجموعه داده	تعداد تصاویر	خطا	ضریب دایس	اشتراک بر روی اجتماع
کرک ۵۰۰	۲۵۰	۰/۰۱۰	۰/۹۶۱	۰/۹۲۵
سی‌اف‌دی	۱۱۸	۰/۰۷۲	۰/۸۷۸	۰/۸۴۸
کرک‌تری ۲۰۰	۲۰۶	۰/۰۶۵	۰/۸۸۵	۰/۸۶۰
دیپ‌کرک	۵۲۱	۰/۰۵۸	۰/۸۹۸	۰/۸۷۲
گپس ۳۸۴	۵۰۹	۰/۰۶۱	۰/۸۹۲	۰/۸۶۷

مدل بهینه که با ۱۰۰۰ تصویر افزایشی (۴۰۰ درصد) روی مجموعه داده کرک ۵۰۰ آموزش دیده است، به خطای برابر ۰/۰۱۰، ضرایب دایس برابر ۰/۹۶۱ و اشتراک بر روی اجتماع برابر ۰/۹۲۵ دست یافت. زمانی که این مدل روی مجموعه‌های داده مختلف آزمایش شد، عملکرد آن به طور جزئی کاهش یافته است. برای مجموعه داده سی‌اف‌دی، مدل دارای خطای برابر ۰/۰۷۲، ضریب دایس برابر ۰/۸۷۸ و اشتراک بر روی اجتماع برابر ۰/۸۴۸ است. در مقایسه با مدل بهینه، این شاخص‌ها پایین‌تر بوده‌اند که نشان می‌دهد مدل برای بخش‌بندی انواع مختلف ترک‌های موجود در مجموعه داده سی‌اف‌دی با چالش بیشتری مواجه بوده است. برای مجموعه داده کرک‌تری ۲۰۰، مدل خطای ۰/۰۶۵، ضریب دایس برابر ۰/۸۸۵ و اشتراک بر روی اجتماع برابر ۰/۸۶۰ را به دست آمده است. این شاخص‌ها به مدل بهینه نزدیک‌تر بوده‌اند که نشان می‌دهد مدل در شبیه‌سازی ترک‌های درخت مانند نسبتاً خوب عمل کرده است. برای مجموعه داده دیپ‌کرک، مدل دارای خطای ۰/۰۵۸، ضریب دایس برابر ۰/۸۹۸ و اشتراک بر روی اجتماع برابر ۰/۸۷۲ می‌باشد. عملکرد مدل نسبتاً کمتر از مدل بهینه بود، که نشان می‌دهد مدل قادر به بخش‌بندی انواع مختلف ترک‌ها و شدت‌ها است اما با چالش‌هایی روبرو است. برای مجموعه داده گپس ۳۸۴، مدل از خطای ۰/۰۶۱، ضریب دایس برابر ۰/۸۹۲ و اشتراک بر روی اجتماع برابر ۰/۸۶۷ برخوردار است. این شاخص‌ها به مدل بهینه نزدیک بودند و نشان می‌دهد که مدل می‌تواند به خوبی تصاویر با وضوح بالا و اطلاعات دقیق‌تر از ترک‌ها را پیش‌بینی کند. در مجموع، مدل بخش‌بندی بهینه توانایی‌های خوبی در مواجهه با مجموعه‌های داده مختلف نشان داد، اگر چه عملکرد آن بسته به ویژگی‌ها و پیچیدگی‌های خاص هر مجموعه داده متفاوت بوده است.

۴- توسعه شاخص وضعیت سطحی روسازی

خرابی‌های آسفالت، به ویژه ترک‌ها، تهدیدی جدی برای دوام و ایمنی سازه‌های راه محسوب می‌شوند. ترک‌ها امکان نفوذ آب را فراهم می‌کنند که می‌تواند ساختار روسازی را تضعیف کرده و منجر به افت بیشتر آن شود. سه نوع اصلی ترک معمولاً مشاهده می‌شوند که ترک طولی، ترک عرضی و ترک پوست سوسماری را شامل می‌شوند. ترک‌های طولی به موازات خط مرکزی روسازی امتداد یافته و اغلب ناشی از اجرای ضعیف درزها یا ترک‌های انعکاسی هستند. ترک‌های عرضی که بر زاویه قائم با خط مرکزی قرار می‌گیرند، معمولاً به دلیل تنش‌های حرارتی یا پیری آسفالت به وجود می‌آیند. ترک‌های پوست سوسماری که با شبکه‌ای از ترک‌های به هم پیوسته شبیه پوست سوسمار شناخته می‌شوند، نشان‌دهنده خرابی خستگی روسازی در اثر بارگذاری مکرر ترافیک یا ضخامت ناکافی روسازی است. برای مدیریت و نگهداری مؤثر روسازی‌های آسفالتی، ارزیابی دقیق میزان و شدت این آسیب‌ها ضروری است. این بخش رویکردی سیستماتیک و خودکار برای تحلیل خرابی‌های آسفالت با استفاده از تکنیک‌های پردازش تصویر بر روی تصاویر ماسک (با استفاده از نتایج به دست آمده در بخش قبل) ورودی ارائه می‌دهد. روش‌شناسی شامل کمی‌سازی پارامترهای کلیدی مانند طول، عرض بازشدگی و تراکم ترک‌ها است که سپس برای محاسبه شاخص وضعیت سطحی روسازی^۱ (SCI) به کار می‌روند. شاخص SCI اندازه‌گیری کمی

¹ Surface Condition Index

از وضعیت روسازی را فراهم می‌آورد و امکان تصمیم‌گیری آگاهانه در مورد فعالیت‌های مناسب تعمیر، نگهداری و بهسازی^۱ (MnR) را میسر می‌سازد.

در این تحلیل از نمودارهای مقدار کسری^۲ (DVC) دیجیتالی‌شده بر اساس کتاب مدیریت روسازی برای فرودگاه‌ها، جاده‌ها و پارکینگ‌ها [۳۹] بهره‌گیری شده است تا شدت هر نوع خرابی تعیین شود. این نمودارها که در کد پیاده‌سازی شده‌اند، چارچوبی استاندارد برای ارزیابی شدت خرابی بر اساس پارامترهای قابل اندازه‌گیری فراهم می‌کنند. برای این منظور، هر پیکسل در تصاویر ماسک ورودی معادل ۱ میلی‌متر در نظر گرفته شده است تا دقت کمی‌سازی ابعاد خرابی تضمین شود.

هدف اصلی این بخش تشریح روش‌شناسی محاسبه پارامترهای خرابی و SCI برای ترک‌های طولی، عرضی و پوست سوسماری است. این شامل محاسبه تراکم خرابی به صورت نسبت پیکسل‌های سفید (نمایانگر ترک‌ها) به کل پیکسل‌های تصویر دودویی، تعیین طول ترک‌های خطی (طول و عرضی) با استفاده از تکنیک‌های اسکلت‌سازی، اندازه‌گیری عرض ترک‌های خطی یا مساحت ترک‌های پوست سوسماری برای ارزیابی شدت، محاسبه SCI بر اساس نوع ترک، شدت و تراکم با استفاده از وزن‌ها و فرمول‌های از پیش تعریف شده، و پیشنهاد فعالیت‌های MnR مناسب بر اساس SCI محاسبه شده و سطوح شدت است. برای این منظور کد طراحی شده است تا تصاویر ماسک ورودی را پردازش کرده، نوع ترک را (در صورت عدم مشخص بودن) به طور خودکار طبقه‌بندی کند و تصویری با اندازه‌گیری‌های حاشیه‌نویسی شده تولید نماید.

همچنین این بخش بر جنبه‌های فنی روش‌شناسی تمرکز دارد و فرمول‌ها و توضیحات هر گام محاسباتی را به صورت تفصیلی ارائه می‌کند. خروجی‌های نمونه، از جمله تصاویر اصلی و اسکلت‌شده با پوشش‌ها، برای هر نوع ترک به منظور نمایش فرآیند تحلیل ارائه شده‌اند. با ارائه توضیحی روشن و جامع از فرآیند تحلیل خرابی‌ها، این بخش قصد دارد منبع ارزشمندی برای مهندسان و پژوهشگران روسازی باشد که در پی پیاده‌سازی یا درک تکنیک‌های ارزیابی وضعیت روسازی مبتنی بر تصویر می‌باشند.

۴-۱- روش‌شناسی

در این بخش، روش خودکار بکار گرفته شده برای تحلیل خرابی‌های روسازی آسفالتی با استفاده از تکنیک‌های پردازش تصویر تشریح شده است. این روش‌شناسی شامل شناسایی انواع خرابی، محاسبه پارامترهای کلیدی (تراکم، طول و عرض بازشدگی)، تعیین شاخص SCI و توصیه فعالیت‌های MnR مناسب است. تحلیل بر اساس روش‌های مدیریت روسازی شناخته شده است و از نمودارهای DVC [۳۹] برای ارزیابی شدت خرابی استفاده می‌کند.

۴-۱-۱- محاسبه پارامترهای خرابی

برای کمی‌سازی گستردگی و شدت خرابی روسازی، سه پارامتر کلیدی محاسبه می‌شوند: تراکم، طول و عرض (یا مساحت برای ترک خوردگی پوست سوسماری). این پارامترها از تصاویر ماسک باینری استخراج می‌شوند که در آنها ترک‌ها با پیکسل‌های سفید (مقدار ۲۵۵) و پس‌زمینه با پیکسل‌های سیاه (مقدار صفر) نمایش داده می‌شوند.

۴-۱-۱-۱- محاسبه تراکم

تراکم معیاری از گستردگی خرابی نسبت به کل مساحت روسازی است. این پارامتر به صورت نسبت پیکسل‌های سفید (ترک‌ها) به کل پیکسل‌های تصویر محاسبه می‌شود (رابطه ۱):

$$D = \frac{N_w}{N_T} \quad (1)$$

که در این رابطه D برابر تراکم خرابی، بر حسب درصد؛ N_w برابر تعداد پیکسل‌های سفید در تصویر باینری، که با اعمال آستانه ۱۲۷ بر تصویر خاکستری به دست می‌آید؛ و N_T برابر تعداد کل پیکسل‌های تصویر (ارتفاع×عرض) است.

¹ Maintenance and Rehabilitation

² Deducted Values Curves

برای ترک‌های طولی و عرضی، معیار دقیق‌تری به نام تراکم شاهین استفاده می‌شود که طول ترک را به مساحت تصویر مرتبط می‌کند (رابطه ۲):

$$D_{Shahin} = \frac{L}{A_{image}} N_{Total} \quad (2)$$

که در این رابطه D_{Shahin} تراکم خرابی بر اساس [۳۹]؛ L برابر طول ترک بر حسب سانتی‌متر؛ A_{image} برابر مساحت تصویر بر حسب سانتی‌متر مربع، که به صورت $N_{Total} \times$ اندازه پیکسل بر حسب سانتی‌متر^۲ محاسبه می‌شود، اندازه هر پیکسل برابر ۱ میلی‌متر است. برای ترک‌خوردگی پوست سوسماری، تراکم [۳۹] بر اساس مساحت خرابی است (رابطه ۳):

$$D_{Shahin} = \frac{A_{polygon}}{A_{image}} \quad (3)$$

که در این رابطه D_{Shahin} تراکم خرابی پوست سوسماری بر اساس [۳۹]؛ $A_{polygon}$ مساحت بدنه محدب دربرگیرنده تمام پیکسل‌های سفید، بر حسب سانتی‌متر مربع است.

۴-۱-۱-۲- محاسبه طول

طول ترک‌های خطی (طولی و عرضی) با استفاده از نسخه اسکلت شده تصویر باینری محاسبه می‌شود، که ترک را به یک نمایش ۱ پیکسل عرض کاهش می‌دهد. طول کل، مجموع فواصل بین نقاط متوالی اسکلت است (رابطه ۴):

$$L = \sum_{i=1}^{n-1} d_i \times pixelsize \quad (4)$$

که در این رابطه L طول ترک؛ n تعداد نقاط در اسکلت با مقدار پیکسل < 0.5 ؛ d_i برابر فاصله بین نقاط متوالی (y_i, x_i) و (y_{i+1}, x_{i+1}) ؛ $d_i = 1$ برای حرکت‌های افقی یا عمودی (پیکسل‌های مجاور)؛ $d_i = \sqrt{2}$ (one being 0)؛ $d_i = \sqrt{2}$ برای حرکت‌های مورب؛ $(|y_{i+1} - y_i| = 1 \text{ and } |x_{i+1} - x_i| = 1)$ ؛ و اندازه پیکسل برابر ۰/۱ سانتی‌متر (۱ میلی‌متر) که فواصل پیکسلی را به سانتی‌متر تبدیل می‌کند. الگوریتم با بررسی پیکسل‌های مجاور (هشت اتصاله) از اتصال اطمینان حاصل می‌کند و طول مسیر را به صورت تجمعی محاسبه می‌کند.

۴-۱-۱-۳- محاسبه عرض

محاسبه عرض بازشدگی بر اساس نوع ترک متفاوت است: ترک‌های طولی و عرضی: میانگین عرض بازشدگی عمود بر اسکلت بر اساس رابطه ۵ محاسبه می‌شود:

$$W = \frac{1}{m} \sum_{j=1}^m w_j \times pixelsize \quad (5)$$

که در این رابطه W عرض ترک؛ m برابر تعداد نقاط اسکلت؛ w_j برابر تعداد پیکسل‌های سفید متوالی در جهت عمود بر ترک در نقطه اسکلت j . این مقدار با روش زیر تعیین می‌شود:

- استفاده از فیلترهای سوبل^۱ برای محاسبه گرادیان‌ها و تعیین جهت ترک؛
- نمونه‌برداری از ۱۰۱ نقطه (۵۰- تا ۵۰+) عمود بر اسکلت با استفاده از زاویه جهت منهای ۹۰ درجه؛
- شمارش پیکسل‌های سفید در محدوده تصویر باینری در امتداد این خط عمود؛
- اندازه پیکسل برابر ۰/۱ سانتی‌متر.

¹ Sobel

ترک‌های پوست سوسماری: به جای عرض بازشدگی، مساحت بدنه محدب دربرگیرنده تمام پیکسل‌های سفید محاسبه می‌شود (رابطه ۶):

$$A_{\text{polygon}} = \text{Area}_{\text{contour}} \times (\text{pixelsize})^2 \quad (6)$$

که در این رابطه A_{polygon} برابر مساحت بدنه محدب دربرگیرنده برای ترک پوست سوسماری، $\text{Area}_{\text{contour}}$ برابر مساحت پیکسلی بدنه محدب، که با استفاده از تابع 'contourArea' در OpenCV محاسبه می‌شود؛ و اندازه پیکسل برابر ۰/۱ سانتی‌متر که مساحت را به سانتی‌متر مربع تبدیل می‌کند. این اندازه‌گیری مساحت، کمی‌سازی جامعی از گستردگی ترک‌خوردگی پوست سوسماری ارائه می‌دهد.

۴-۱-۲- محاسبه شاخص SCI

شاخص وضعیت سطحی روسازی (SCI) یک معیار ترکیبی است که وضعیت روسازی را بر اساس نوع ترک، شدت و تراکم ارزیابی می‌کند. این شاخص با استفاده از رابطه ۷ محاسبه می‌شود:

$$SCI = \sum (W_i \times S_i \times E_i) \times 100 \quad (7)$$

که در این رابطه SCI شاخص وضعیت سطحی روسازی؛ W برابر وزن نوع ترک (نرمال شده، به طوری که وزن‌ها نسبت به حداکثر وزن تنظیم شده‌اند تا جمع آن‌ها به مقیاس مناسبی برسد و اهمیت نسبی هر نوع خرابی را نشان دهد):

- ترک خطی (طولی و عرضی): ۰/۳۶۶ و ترک پوست سوسماری: ۰/۶۳۳ می‌باشد.

S_i برابر وزن شدت:

- کم: ۰/۳۳۳، متوسط: ۰/۶۶۷ و زیاد: ۱ می‌باشد.

E_i : تراکم خرابی بر اساس ۱-۴: برابر وسعت هر خرابی (۱ متر برای ترک خطی (طولی و عرضی) و ترک پوست سوسماری بدون واحد) که مقادیر آن با استفاده از روش حداقل-حداکثر مقیاس‌دهی^۱ شده‌اند (مقادیر مقیاس‌دهی شده وسعت، گستره نامیده شده‌اند)؛ - ضریب ۱۰۰ برای تبدیل شاخص وضعیت سطحی روسازی به درصد استفاده می‌شود تا مقیاس آن بین صفر تا ۱۰۰ قرار گیرد. شدت بر اساس استاندارد ای‌اس‌تی‌ام دی ۶۴۳۳ و ها و همکاران [۴۰، ۴۱] تعیین شده است:

- برای ترک خطی (طولی و عرضی)، شدت بر اساس عرض میانگین ترک (سانتی‌متر) تعیین می‌شود: شدت کم اگر عرض کمتر از ۱ سانتی‌متر باشد، شدت متوسط اگر عرض بین ۱ تا کمتر از ۷/۵ سانتی‌متر (شامل مرزها) باشد، و شدت زیاد اگر عرض ۷/۵ سانتی‌متر یا بیشتر باشد؛

- برای تعیین شدت ترک پوست سوسماری ای‌اس‌تی‌ام دی ۶۴۳۳، معیارها به صورت کیفی توصیف شده‌اند که بر پایه وسعت پوشش ترک‌ها، اندازه عرض‌ها و الگوی کلی شبکه‌ای تمرکز دارد. در شدت کم ترک‌های نازک/مویی موازی با اتصالات کم بین ترک‌ها وجود داشته و ترک‌ها لب پر نشده‌اند، در شدت متوسط شبکه اتصالات بین ترک‌ها بیشتر شکل گرفته و ترک‌ها کمی لب پر شده‌اند و همچنین در شدت زیاد شبکه کامل شکل گرفته و قطعات دقیقاً دیده شده و برخی کنده شده و ترک‌ها لب پر شده‌اند. این معیارهای کیفی بر اساس مشاهدات بصری و تجربی تعریف شده‌اند تا ارزیابی میدانی را تسهیل کنند، اما در پژوهش حاضر برای افزایش دقت و قابلیت محاسباتی، به صورت کمی تبدیل شده‌اند:

۱- برای شدت کم: تراکم کمتر از ۱۰ درصد، همه عرض‌ها کمتر از ۱۰ میلی‌متر و حداقل ۹۵ درصد عرض‌ها کمتر از آستانه متوسط (که آستانه متوسط خودش به صورت ۷۵ امین صدک + یک پنجم برابر دامنه میان‌چهارکی محاسبه می‌شود؛ یعنی از تمام عرض‌های اندازه‌گیری شده در ترک‌ها، ۹۵ درصد یا بیشتر باید کمتر از این مقدار آستانه باشند که این شرط تضمین می‌کند توزیع عرض‌ها عمدتاً کوچک یا بدون ترک باشد)؛

۲- برای شدت متوسط: تراکم بین ۱۰ تا کمتر از ۳۰ درصد، همه عرض‌ها بین ۱۰ تا ۷۵ میلی‌متر (شامل مرزها) و حداقل ۵ درصد عرض‌ها بین آستانه متوسط (۷۵ امین صدک + یک پنجم برابر دامنه میان‌چهارکی) تا آستانه زیاد (شامل مرزها، که آستانه زیاد به صورت

¹ Min-Max Normalization

۷۵٪ صدک + سه برابر دامنه میان چهارکی تعریف می‌شود؛ یعنی حداقل ۵ درصد از عرض‌ها باید در این بازه متوسط تا زیاد قرار گیرند تا نشان دهنده ترکیبی از عرض‌های متوسط و کمی بزرگ‌تر باشد؛

۳- برای شدت زیاد: تراکم حداقل ۳۰ درصد، همه عرض‌ها بیش از ۷۵ میلی‌متر و حداقل ۵ درصد عرض‌ها بیش از آستانه زیاد (۷۵٪ صدک + سه برابر دامنه میان چهارکی؛ یعنی حداقل ۵ درصد از عرض‌ها باید از این آستانه عبور کنند تا توزیع عرض‌ها نشان دهنده ترک‌های بزرگ باشد).

اگر شرایط ترکیبی برقرار نباشد، تنها به وسعت ترک تنها بستگی دارد: شدت کم برای کمتر از ۱۰ درصد، متوسط برای ۱۰ تا کمتر از ۳۰ درصد و زیاد برای حداقل ۳۰ درصد.

۴-۱-۳- فعالیت‌های تعمیر، نگهداری و بهسازی

بر اساس SCI محاسبه شده، شدت و نوع ترک، فعالیت‌های MnR مناسب توصیه شده‌اند. بر اساس دستورالعمل‌های زیر تصمیم‌گیری در خصوص اختصاص انواع فعالیت‌ها صورت می‌گیرد. انواع فعالیت‌های MnR برای هر ترکیب از نوع ترک و شدت بر اساس [۴۰، ۴۱] انتخاب شده است. همچنین این روش ساختاریافته اطمینان می‌دهد که توصیه‌های MnR متناسب با ویژگی‌های خاص خرابی روسازی باشند، تخصیص منابع را بهینه‌سازی کنند و عمر روسازی را افزایش دهند.


۴-۲- ارزیابی وضعیت سطحی روسازی

در این بخش نتایج حاصل از تحلیل خرابی‌های روسازی آسفالتی با استفاده از تکنیک‌های پردازش تصویر ارائه شده است. این نتایج شامل شناسایی و طبقه‌بندی انواع خرابی (ترک‌های طولی، عرضی و پوست سوسماری)، محاسبه پارامترهای کلیدی مانند طول، عرض و تراکم، محاسبه شاخص SCI و پیشنهاد فعالیت‌های MnR است. نمایش‌های تصویری و داده‌های کمی نقش حیاتی در تفسیر و درک این نتایج ایفا می‌کنند و به مهندسان و تصمیم‌گیرندگان کمک می‌کنند تا وضعیت روسازی را به صورت بصری و تحلیلی ارزیابی کرده و تصمیمات مناسبی برای مدیریت آن اتخاذ کنند.


نمایش‌های تصویری مورد استفاده در این تحلیل شامل دو نوع تصویر اصلی است که برای هر نوع خرابی (طولی، عرضی و پوست سوسماری) تولید می‌شوند. این تصاویر به شرح زیر هستند: (۱) تصویر اصلی بدون لایه پوششی: این تصویر، ماسک ورودی خاکستری را بدون هیچ‌گونه لایه پوششی نشان می‌دهد. این تصویر با اطلاعات اندازه‌گیری شده مانند طول، عرض (یا مساحت برای ترک‌های پوست سوسماری)، تراکم، شدت، SCI و فعالیت‌های MnR پیشنهادی حاشیه‌نویسی می‌شود. این نمایش به کاربران امکان می‌دهد تا وضعیت کلی خرابی را به صورت مستقیم و با جزئیات کلیدی مشاهده کنند. تصویر اصلی به عنوان مرجعی برای درک موقعیت و ویژگی‌های خرابی عمل می‌کند و اطلاعات کمی را به صورت متنی در کنار تصویر ارائه می‌دهد. (۲) تصویر اسکلت شده با لایه پوششی (برای ترک‌های پوست سوسماری): تصویر اسکلت شده، نسخه‌ای از تصویر باینری است که ترک‌ها به یک نمایش ۱ پیکسل عرض کاهش یافته‌اند. این فرآیند برای محاسبه دقیق طول ترک‌های خطی (طولی و عرضی) و همچنین برای نمایش بهتر ترک‌های پوست سوسماری استفاده می‌شود. در مورد ترک‌های پوست سوسماری، یک لایه پوششی چندضلعی قرمز به تصویر اضافه می‌شود که محدوده بدنه محدب دربرگیرنده تمام پیکسل‌های سفید (ترک‌ها) را نشان می‌دهد. این لایه پوششی به برجسته‌سازی مساحت تحت تأثیر خرابی کمک می‌کند و درک بصری از گستردگی ترک‌های پوست سوسماری را بهبود می‌بخشد. برای ترک‌های طولی و عرضی (شکل ۱۲)، تصویر اسکلت شده بدون لایه پوششی ارائه می‌شود، زیرا تمرکز بر طول و عرض ترک است.

نتایج تحلیل نشان دهنده توانایی روش‌های پردازش تصویر در شناسایی دقیق و کمی‌سازی خرابی‌های روسازی آسفالتی است. با محاسبه پارامترهایی مانند تراکم (نسبت پیکسل‌های سفید به کل پیکسل‌ها)، طول (برای ترک‌های خطی)، و عرض یا مساحت (برای ترک‌های پوست سوسماری)، شدت هر خرابی ارزیابی می‌شود. شاخص SCI که از ترکیب وزن نوع ترک، وزن شدت و تراکم به دست می‌آید، معیاری کمی برای ارزیابی وضعیت کلی روسازی ارائه می‌دهد. این شاخص به عنوان پایه‌ای برای پیشنهاد فعالیت‌های MnR استفاده می‌شود.

برای ترک‌های پوست سوسماری که ماهیتی شبکه‌ای و گسترده دارند، استفاده از لایه پوششی چندضلعی در تصویر اسکلت شده (شکل ۱۳) از اهمیت محاسباتی بالایی برخوردار است. دلیل این امر آن است که برخلاف ترک‌های خطی، معیار سنجش این نوع خرابی مساحت است و این تکنیک با ترسیم محیط هندسی پیرامون الگوی ترک‌ها، آن‌ها را به یک ناحیه یکپارچه و قابل اندازه‌گیری تبدیل می‌کند تا محدوده دقیق خرابی و شدت آن تعیین گردد. این فرآیند به مهندسان امکان می‌دهد تا با دقتی فراتر از بازرسی چشمی، نواحی بحرانی نیازمند بهسازی عمقی را شناسایی کنند. در مقابل، برای ترک‌های خطی (طولی و عرضی)، تمرکز بر هندسه خطی است؛ لذا تصویر اصلی همراه با حاشیه‌نویسی‌های متنی که ابعاد دقیق طول و عرض بازشدگی ترک را به صورت مستقیم استخراج و ارائه می‌دهند، برای محاسبات درزگیری و برنامه‌ریزی نگهداری پیشگیرانه کفایت می‌کند.



شکل ۱۲: نمونه‌هایی از ترک‌های طولی و عرضی به همراه نتایج محاسبه شاخص SCI
 Figure 12. Examples of longitudinal and transverse cracks alongside the results of SCI calculation



شکل ۱۳: نمونه‌هایی از ترک پوست سوسماری به همراه نتایج محاسبه شاخص SCI
 Figure 13. Examples of alligator cracks alongside the results of SCI calculation

۵- نتیجه‌گیری

در این پژوهش به موضوع کمبود مجموعه داده‌ها در تشخیص ترک‌های آسفالت با استفاده از مدل‌های یادگیری عمیق پرداخته شد و از تولید داده‌های مصنوعی همراه با مدل‌های مولد بهره گرفته شد. علیرغم پیشرفت‌های چشمگیر در مدل‌های مبتنی بر یادگیری عمیق، کمبود داده‌های آموزشی جامع و با کیفیت بالا همچنان عملکرد مدل‌ها را محدود می‌کند. این تحقیق بر سه هدف اصلی متمرکز بود: (۱) تولید تصاویر مصنوعی با کیفیت بالا از ترک‌های با الگوی پیچیده با استفاده از مدل WGAN-GP، (۲) تعیین درصد بهینه افزایش داده‌های مصنوعی برای بهبود عملکرد بخش‌بندی و (۳) ارزیابی تعمیم‌پذیری مدل‌ها بر روی مجموعه داده‌های دنیای واقعی. همچنین با ترکیب مدل‌های WGAN-GP و یونت، یک شاخص برای وضعیت سطحی روسازی ارائه و مورد ارزیابی قرار گرفته است. مهم‌ترین یافته‌های پژوهش به شرح زیر خلاصه شده است:

- مدل WGAN-GP توانست تصاویر مصنوعی واقع‌گرایانه از ترک‌های آسفالت تولید کند، همان‌طور که در ارزیابی‌های مختلف از جمله خطای میانگین مربعات برابر با ۰/۰۴، شاخص شباهت ساختاری برابر با ۰/۸۹، ضریب دایس برابر با ۰/۹۰ و نسبت بیشینه سیگنال به نویز برابر با ۳۱ مشاهده شده است. این نتایج توانایی تولیدکننده در تقریب نزدیک به داده‌های واقعی را نشان می‌دهد و منابع افزایش داده ارزشمندی برای آموزش فراهم می‌آورد؛
- مدل یونت با استفاده از مجموعه داده کرک ۵۰۰ با مقدار خطای برابر ۰/۰۳۲، ضریب دایس برابر با ۰/۹۲۹ و اشتراک بر روی اجتماع برابر با ۰/۸۶۸ آموزش داده شده است. افزایش مجموعه داده با ۱۰۰۰ تصویر مصنوعی (افزایش ۴۰۰ درصدی) منجر به بهبود بهینه شد، به طوری که از مقدار خطا به ۰/۰۱۰ کاهش یافت، ضریب دایس برابر ۰/۹۶۱ و اشتراک بر روی اجتماع برابر ۰/۹۲۵ افزایش یافت که کارایی داده‌های مصنوعی را در تقویت عملکرد مدل نشان می‌دهد؛
- آزمایش تعمیم‌پذیری مدل یونت بهینه (آموزش داده شده با ۴۰٪ داده‌های افزایش یافته) بر روی مجموعه داده‌های سی افدی، کرک‌تری ۲۰۰، دیپ‌کرک و گپس ۳۸۴ انجام شد. مدل عملکرد پایدار نشان داد؛ اگر چه نتایج بر اساس ویژگی‌های مجموعه داده تغییر کرده و کاهش یافته است. معیارهای عملکرد شامل خطا بین ۰/۰۵۸ تا ۰/۰۷۲، ضریب دایس بین ۰/۸۷۸

تا ۰/۸۹۲ و مقادیر اشتراک بر روی اجتماع بین ۰/۸۴۸ تا ۰/۸۷۲ بوده است که قابلیت انطباق مدل را در شرایط مختلف تأیید می‌کند؛

- نتایج مورد بررسی پتانسیل قابل توجه مدل WGAN-GP همراه با مدل یونت را برای بهبود توسعه‌های خودکار ارزیابی وضعیت روسازی نشان می‌دهد. با رفع کمبود داده، بهبود تعمیم‌پذیری مدل و کاهش وابستگی به روش‌های پرهزینه و دستی، این تحقیق راه را برای راه‌حل‌های خودکار مقیاس‌پذیر، کارآمد و قابل اعتماد در ارزیابی وضعیت روسازی و سایر کاربردهای مدیریت سیستم مدیریت روسازی فراهم می‌کند؛
- مدل پیشنهادی با محاسبه SCI بر اساس بخش‌بندی دقیق ترک‌ها، ارزیابی وضعیت خودکار روسازی را تسهیل کرده و تغییرات سطحی را با دقت بالا پیش‌بینی می‌نماید که این امر به حفظ دوام سازه‌ای و برنامه‌ریزی بهینه نگهداری کمک رسانده و نسبت به روش‌های سنتی، کارایی را به صورت قابل توجهی بهبود می‌بخشد؛
- اگر چه تاکنون روش‌های گوناگونی برای ارزیابی روسازی معرفی شده‌اند، اما روش ترکیبی پیشنهادی در این پژوهش که تلفیقی از مدل مولد WGAN-GP و شبکه بخش‌بندی U-Net است، یک چارچوب تمام خودکار را بدون نیاز به دخالت کاربر ارائه شد که دارای مزیت‌های اساسی نسبت به رویکردهای پیشین است. نخست اینکه مدل WGAN-GP توسعه یافته در این پژوهش با استفاده از فاصله واسرشتاین با جریمه گرادیان، بر خلاف روش‌های سنتی افزایش داده و GAN‌های استاندارد که اغلب دچار ناپایداری می‌شوند، پایداری آموزش را تضمین کرده و با تولید تصاویر مصنوعی متنوع، مشکل عدم توازن داده‌ها را حل نموده است. دومین مزیت، دستیابی به دقت بالا در بخش‌بندی سطح پیکسل است؛ به طوری که با بهره‌گیری از معماری U-Net امکان بخش‌بندی دقیق را فراهم شده و بر خلاف تشخیص‌های جعبه‌ای، مورفولوژی دقیق ترک (شامل طول، عرض و مساحت) را برای محاسبات مهندسی استخراج شده است. سومین ویژگی برجسته، قابلیت تعمیم‌پذیری خوب در شرایط محیطی متنوع است؛ نتایج نشان داد که مدل پیشنهادی عملکرد پایدار و مناسبی در آزمایش بر روی مجموعه داده‌های دیگر و متفاوت داشته و توانایی تطبیق با طیف وسیعی از متغیرهای محیطی شامل بافت‌های مختلف آسفالت، شرایط نوری گوناگون (سایه، آفتاب شدید) و همچنین وضعیت‌های آب و هوایی متفاوت را داده بوده که این امر نشان دهنده قابلیت تعمیم‌پذیری آن می‌باشد. در نهایت، رویکرد این پژوهش با تولید خروجی‌های کاربردی برای تصمیم‌گیری و تبدیل خروجی‌های گرافیکی مدل به یک شاخص کمی وضعیت سطحی (SCI)، فرآیند تبدیل داده به دانش مدیریتی را به صورت خودکار انجام داده و مستقیماً در اولویت‌بندی عملیات نگهداری و تعمیرات قابل استفاده می‌باشد.

۶- تشکر و قدردانی

این اثر تحت حمایت مادی بنیاد ملی علم ایران (INSF) بر گرفته شده از طرح شماره (۴۰۲۵۵۷۱) انجام شده است.

۷- مراجع

- [1] K.G. Murty, Letter to the Editor—An Algorithm for Ranking all the Assignments in Order of Increasing Cost, <https://doi.org/10.1287/OPRE.16.3.682> 16 (1968) 682–687. <https://doi.org/10.1287/OPRE.16.3.682>.
- [2] M. Sedighian-Fard, N. Solatifar, H. Sivilevičius, Calibration of regression-based models for prediction of temperature profile of asphalt layers using LTPP data, *Journal of Civil Engineering and Management* 29 (2023) 329–341–329–341. <https://doi.org/10.3846/JCEM.2023.18611>.
- [3] S. Mathavan, K. Kamal, M. Rahman, A Review of Three-Dimensional Imaging Technologies for Pavement Distress Detection and Measurements, *IEEE Transactions on Intelligent Transportation Systems* 16 (2015) 2353–2362. <https://doi.org/10.1109/TITS.2015.2428655>.
- [4] P. Marcelino, M. de Lurdes Antunes, E. Fortunato, Comprehensive performance indicators for road pavement condition assessment, <https://doi.org/10.1080/15732479.2018.1446179> 14 (2018) 1433–1445. <https://doi.org/10.1080/15732479.2018.1446179>.

- [5] V. V. Silyanov, J.I. Sodikov, R. Kiran, A.I. Sadikov, An overview road data collection, visualization, and analysis from the perspective of developing countries, *IOP Conf Ser Mater Sci Eng* 832 (2020). <https://doi.org/10.1088/1757-899X/832/1/012056>.
- [6] M. Gouda, I. Chowdhury, J. Weiß, A. Epp, K. El-Basyouny, Automated assessment of infrastructure preparedness for autonomous vehicles, *Autom Constr* 129 (2021). <https://doi.org/10.1016/j.autcon.2021.103820>.
- [7] M. Fahmani, A. Golroo, M. Sedighian-Fard, Deep learning-based predictive models for pavement patching and manholes evaluation, *International Journal of Pavement Engineering* 25 (2024). <https://doi.org/10.1080/10298436.2024.2349901>.
- [8] M. Sezgin, B. Sankur, Survey over image thresholding techniques and quantitative performance evaluation, *https://doi.org/10.1117/1.1631315* 13 (2004) 146–165. <https://doi.org/10.1117/1.1631315>.
- [9] N.J. Sugang, M. Ramos, N.A. Arriola, Road Surface Obstacle Detection using Vision and LIDAR for Autonomous Vehicle, *Lecture Notes in Engineering and Computer Science* 2227 (2017) 260–264.
- [10] S. Chambon, J.M. Moliard, Automatic Road Pavement Assessment with Image Processing: Review and Comparison, *International Journal of Geophysics* 2011 (2011) 989354. <https://doi.org/10.1155/2011/989354>.
- [11] Y.-A. Hsieh, Y.J. Tsai, Machine Learning for Crack Detection: Review and Model Performance Comparison, *Journal of Computing in Civil Engineering* 34 (2020) 04020038. [https://doi.org/10.1061/\(asce\)cp.1943-5487.0000918](https://doi.org/10.1061/(asce)cp.1943-5487.0000918).
- [12] D. Arya, H. Maeda, S.K. Ghosh, D. Toshniwal, A. Mraz, T. Kashiya, Y. Sekimoto, Deep learning-based road damage detection and classification for multiple countries, *Autom Constr* 132 (2021) 103935. <https://doi.org/10.1016/J.AUTCON.2021.103935>.
- [13] Y. Shi, L. Cui, Z. Qi, F. Meng, Z. Chen, Automatic road crack detection using random structured forests, *IEEE Transactions on Intelligent Transportation Systems* 17 (2016) 3434–3445. <https://doi.org/10.1109/TITS.2016.2552248>.
- [14] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, Generative adversarial networks, *Commun ACM* 63 (2020) 139–144. <https://doi.org/10.1145/3422622>.
- [15] J. Zhong, J. Huan, W. Zhang, H. Cheng, J. Zhang, Z. Tong, X. Jiang, B. Huang, A deeper generative adversarial network for grooved cement concrete pavement crack detection, *Eng Appl Artif Intell* 119 (2023). <https://doi.org/10.1016/j.engappai.2022.105808>.
- [16] C. Han, T. Ma, J. Huan, Z. Tong, H. Yang, Y. Yang, Multi-stage generative adversarial networks for generating pavement crack images, *Eng Appl Artif Intell* 131 (2024). <https://doi.org/10.1016/j.engappai.2023.107767>.
- [17] M. Arjovsky, S. Chintala, L. Bottou, Wasserstein GAN, *ArXiv* (2017) 1–32. <https://arxiv.org/pdf/1701.07875> (accessed July 12, 2025).
- [18] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin, A. Courville, Improved Training of Wasserstein GANs, *Adv Neural Inf Process Syst* 2017-December (2017) 5768–5778. <https://arxiv.org/abs/1704.00028v3> (accessed October 25, 2024).
- [19] M. Mirza, S. Osindero, Conditional Generative Adversarial Nets, (2014). <https://arxiv.org/abs/1411.1784v1> (accessed December 8, 2024).
- [20] J.Y. Zhu, T. Park, P. Isola, A.A. Efros, Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks, *Proceedings of the IEEE International Conference on Computer Vision* 2017-October (2017) 2242–2251. <https://doi.org/10.1109/ICCV.2017.244>.
- [21] H. Maeda, T. Kashiya, Y. Sekimoto, T. Seto, H. Omata, Generative adversarial network for road damage detection, *Computer-Aided Civil and Infrastructure Engineering* 36 (2021) 47–60. <https://doi.org/10.1111/MICE.12561>.

- [22] D. Ma, H. Fang, N. Wang, C. Zhang, J. Dong, H. Hu, Automatic Detection and Counting System for Pavement Cracks Based on PCGAN and YOLO-MF, *IEEE Transactions on Intelligent Transportation Systems* 23 (2022) 22166–22178. <https://doi.org/10.1109/TITS.2022.3161960>.
- [23] B. Xu, C. Liu, Pavement crack detection algorithm based on generative adversarial network and convolutional neural network under small samples, *Measurement* 196 (2022) 111219. <https://doi.org/10.1016/J.MEASUREMENT.2022.111219>.
- [24] K. Zhang, Y. Zhang, H. Da Cheng, CrackGAN: Pavement Crack Detection Using Partially Accurate Ground Truths Based on Generative Adversarial Learning, *IEEE Transactions on Intelligent Transportation Systems* 22 (2021) 1306–1319. <https://doi.org/10.1109/TITS.2020.2990703>.
- [25] Q. Mei, M. Gül, A cost effective solution for pavement crack inspection using cameras and deep neural networks, *Constr Build Mater* 256 (2020) 119397. <https://doi.org/10.1016/J.CONBUILDMAT.2020.119397>.
- [26] Y. Que, Y. Dai, X. Ji, A. Kwan Leung, Z. Chen, Y. Tang, Z. Jiang, Automatic classification of asphalt pavement cracks using a novel integrated generative adversarial networks and improved VGG model, *Eng Struct* 277 (2023) 115406. <https://doi.org/10.1016/J.ENGSTRUCT.2022.115406>.
- [27] T. Zhang, D. Wang, A. Mullins, Y. Lu, Integrated APC-GAN and AttuNet Framework for Automated Pavement Crack Pixel-Level Segmentation: A New Solution to Small Training Datasets, *IEEE Transactions on Intelligent Transportation Systems* 24 (2023) 4474–4481. <https://doi.org/10.1109/TITS.2023.3236247>.
- [28] S. Yu, S. Jia, C. Xu, Convolutional neural networks for hyperspectral image classification, *Neurocomputing* 219 (2017) 88–98. <https://doi.org/10.1016/J.NEUCOM.2016.09.010>.
- [29] A. Karpathy, G. Toderici, S. Shetty, T. Leung, R. Sukthankar, F.F. Li, Large-scale video classification with convolutional neural networks, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (2014) 1725–1732. <https://doi.org/10.1109/CVPR.2014.223>.
- [30] J. König, M. Jenkins, M. Mannion, P. Barrie, G. Morison, Optimized Deep Encoder-Decoder Methods for Crack Segmentation, *Digital Signal Processing: A Review Journal* 108 (2020). <https://doi.org/10.1016/j.dsp.2020.102907>.
- [31] Z. Fan, C. Li, Y. Chen, P. Di Mascio, X. Chen, G. Zhu, G. Loprencipe, Ensemble of Deep Convolutional Neural Networks for Automatic Pavement Crack Detection and Measurement, *Coatings* 2020, Vol. 10, Page 152 10 (2020) 152. <https://doi.org/10.3390/COATINGS10020152>.
- [32] Z. Fan, C. Li, Y. Chen, J. Wei, G. Loprencipe, X. Chen, P. Di Mascio, Automatic Crack Detection on Road Pavements Using Encoder-Decoder Architecture, *Materials* 2020, Vol. 13, Page 2960 13 (2020) 2960. <https://doi.org/10.3390/MA13132960>.
- [33] W. Song, Z. Zhang, B. Zhang, G. Jia, H. Zhu, J. Zhang, ISTD-PDS7: A Benchmark Dataset for Multi-Type Pavement Distress Segmentation from CCD Images in Complex Scenarios, *Remote Sens (Basel)* 15 (2023). <https://doi.org/10.3390/rs15071750>.
- [34] CRACK500-20220509T090436Z-001 | Kaggle, (n.d.). <https://www.kaggle.com/datasets/pauldavid22/crack50020220509t090436z001> (accessed September 5, 2023).
- [35] I.J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, Generative Adversarial Networks, *Sci Robot* 3 (2014) 2672–2680. <https://arxiv.org/abs/1406.2661v1> (accessed April 22, 2025).
- [36] W. Weng, X. Zhu, U-Net: Convolutional Networks for Biomedical Image Segmentation, *IEEE Access* 9 (2015) 16591–16603. <https://doi.org/10.1109/ACCESS.2021.3053408>.
- [37] GitHub - milesial/Pytorch-UNet: PyTorch implementation of the U-Net for image semantic segmentation with high quality images, (n.d.). <https://github.com/milesial/Pytorch-UNet> (accessed April 22, 2025).

- [38] GitHub - GohVh/resnet34-unet: Segmentation model using UNET architecture with ResNet34 as encoder background, designed with PyTorch., (n.d.). <https://github.com/GohVh/resnet34-unet> (accessed April 22, 2025).
- [39] M.Y. Shahin, Pavement management for airports, roads, and parking lots: Second Edition, Pavement Management for Airports, Roads, and Parking Lots: Second Edition (2005) 1–572. <https://doi.org/10.1007/B101538>.
- [40] ASTM, Practice for Roads and Parking Lots Pavement Condition Index Surveys - ASTM D6433-20, (2020). <https://doi.org/10.1520/D6433-20>.
- [41] J. Ha, D. Kim, M. Kim, Assessing severity of road cracks using deep learning-based segmentation and detection, The Journal of Supercomputing 2022 78:16 78 (2022) 17721–17735. <https://doi.org/10.1007/S11227-022-04560-X>.