

# پردازش تصویر دوبعدی برای شناسایی خودکار خرابی چاله در روسازی آسفالتی (مقایسه رویکردهای ویژگی محور و یادگیری ماشین)

## مقاله علمی-پژوهشی

\*محمد علی تابعی (نویسنده مسئول)، دانش آموخته کارشناسی ارشد، گروه راه و ترابری، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران،

تهران، ایران

حسین عالی نژادیان، دانشجوی دکتری، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، سمنان، ایران

برات مجردی، دانشیار، گروه راه و ترابری، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران

محمود عامری، استاد، گروه راه و ترابری، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران

\*پست الکترونیکی نویسنده مسئول: [tabeei.mohammadali1994@gmail.com](mailto:tabeei.mohammadali1994@gmail.com)

دریافت: ۱۴۰۴/۰۵/۰۵ - پذیرش: ۱۴۰۴/۱۰/۰۲

صفحه ۳۹۲-۳۷۵

## چکیده

شناسایی دقیق و به موقع خرابی‌ها در روسازی آسفالتی، نقشی اساسی در ایمنی و پایداری عملکرد راه‌ها دارد. روش‌های سنتی مانند بازرسی چشمی، با محدودیت‌هایی نظیر خطای انسانی، هزینه بالا و عدم تکرارپذیری مواجه‌اند. در این پژوهش، با استفاده از پردازش تصویر دوبعدی، دو رویکرد متفاوت شامل روش ویژگی‌محور و یادگیری ماشین برای شناسایی خودکار خرابی چاله مورد بررسی و مقایسه قرار گرفته‌اند. ابتدا مجموعه‌ای از تصاویر دارا و فاقد چاله گردآوری و با اعمال مراحل پیش‌پردازش، ویژگی‌های مؤثر استخراج گردید. سپس الگوریتم‌های مختلف طبقه‌بندی شامل ماشین بردار پشتیبان (SVM)، K نزدیک‌ترین همسایه، درخت تصمیم و جنگل تصادفی آموزش داده شدند. نتایج تجربی نشان داد که الگوریتم SVM با کرنل خطی، با دقتی بیش از ۹۷ درصد، در تفکیک تصاویر دارای چاله عملکرد بهتری دارد. رویکرد پیشنهادی با وجود سادگی محاسباتی، توانسته است، دقت بالا و کارایی رضایت‌بخش در مقایسه با روش‌های سنتی، تحت شرایط نوری کنترل‌شده (هوای ابری) و زاویه تصویربرداری ثابت را فراهم آورد. این روش می‌تواند به‌عنوان جایگزینی عملی و کم‌هزینه برای بازرسی بصری در مدیریت نگهداری روسازی‌ها مورد استفاده قرار گیرد.

واژه‌های کلیدی: شناسایی خرابی‌های روسازی، پردازش تصویر، استخراج ویژگی، یادگیری ماشین

## ۱- مقدمه

چاله‌ها و سایر خرابی‌های سطحی روسازی آسفالتی، تأثیر مستقیمی بر ایمنی، آسایش رانندگان و هزینه‌های نگهداری شبکه راه‌ها دارند. روش‌های سنتی بازرسی میدانی به دلیل زمان‌بر بودن، هزینه بالا و پوشش مکانی محدود، کارایی و بهره‌وری فرآیند پایش را کاهش می‌دهند (Koch et al., 2015; Perka & Biligiri, 2020) با پیشرفت فناوری حسگرها، پردازش تصویر و هوش مصنوعی، امکان شناسایی خودکار چاله‌ها فراهم شده است. پردازش تصویر دوبعدی، به ویژه در ترکیب با الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی، می‌تواند دقت بالایی در شناسایی خرابی‌ها ارائه دهد و در عین حال مقرون به صرفه و قابل پیاده‌سازی روی تجهیزات ساده باشد (Lydon et al., 2020; Schnebele et al., 2015; Ma et al., 2022; Ranyal et al., 2022; Tamagusko et al., 2024; Safyari et al., 2024; Rizelioglu, 2025). هدف این مطالعه، ارائه یک تحلیل فنی و مقایسه‌ای از روش‌های

چاله‌ها و سایر خرابی‌های سطحی روسازی آسفالتی، تأثیر مستقیمی بر ایمنی، آسایش رانندگان و هزینه‌های نگهداری شبکه راه‌ها دارند. روش‌های سنتی بازرسی میدانی به دلیل زمان‌بر بودن، هزینه بالا و پوشش مکانی محدود، کارایی و بهره‌وری فرآیند پایش را کاهش می‌دهند (Koch et al., 2015; Perka & Biligiri, 2020) با پیشرفت فناوری حسگرها، پردازش تصویر و هوش مصنوعی، امکان شناسایی خودکار چاله‌ها فراهم شده است. پردازش تصویر دوبعدی، به ویژه در ترکیب با الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی، می‌تواند دقت بالایی در شناسایی خرابی‌ها ارائه دهد و در عین حال مقرون به صرفه و قابل پیاده‌سازی روی تجهیزات ساده باشد (Lydon et al., 2020; Schnebele et al., 2015; Ma et al., 2022; Ranyal et al., 2022; Tamagusko et al., 2024; Safyari et al., 2024; Rizelioglu, 2025). هدف این مطالعه، ارائه یک تحلیل فنی و مقایسه‌ای از روش‌های

ویژگی محور و یادگیری ماشین برای شناسایی خودکار خرابی چاله با استفاده از تصاویر دوبعدی است تا محدودیت‌های روش‌های سنتی و پیچیده کاهش یافته و مسیر توسعه سیستم‌های هوشمند پیش‌رو سازی هموار گردد.

## ۲- پیشینه تحقیق

شناسایی خودکار خرابی چاله در روسازی آسفالتی یکی از مسائل کلیدی در مدیریت نگهداری راه‌هاست و تاکنون رویکردهای گوناگونی برای این هدف توسعه یافته‌اند. این رویکردها را می‌توان به چهار دسته اصلی تقسیم کرد: روش‌های مبتنی بر حسگر و ارتعاش، بازسازی سه‌بعدی، پردازش تصویر دوبعدی همراه با یادگیری ماشین، و ادغام داده‌های چند منبعی. در روش‌های ارتعاشی، از شتاب‌سنج‌ها و ژيروسکوپ‌ها برای پایش مسیر حرکت خودرو و شناسایی چاله‌ها استفاده می‌شود. این رویکردها به دلیل هزینه پایین، سرعت بالا و سادگی پیاده‌سازی، معمولاً دقتی در حدود ۷۵ تا ۸۵ درصد دارند (Zhang et al., 2022; Alvarez-Garcia et al., 2022; Lv et al., 2025; Georgopoulos et al., 1995). با این حال، وابستگی به رفتار راننده و مسیر حرکت، نویز سیگنال و ناتوانی در تفکیک انواع خرابی‌ها از جمله محدودیت‌های مهم این دسته از روش‌ها به شمار می‌روند (Wang et al., 2017; Tsai & Chatterjee, 2017; Ye et al., 2019). رویکرد بازسازی سه‌بعدی با بهره‌گیری از لیدار، اسکنر لیزری و دوربین‌های استریو توانسته است دقتی نزدیک به ۹۵ درصد در تشخیص خرابی‌ها ارائه دهد (Aparna et al., 2019; Becker et al., 2019; Ochoa-Ruiz et al., 2020; Ren et al., 2023; Fan et al., 2021; Fan et al., 2021). این روش‌ها اگرچه از نظر دقت و توصیف هندسی سطح آسیب دیده ارزش علمی بالایی دارند، اما هزینه زیاد، پیچیدگی سخت افزاری و نیاز به پردازش محاسباتی سنگین، مانعی برای به کارگیری گسترده‌ی آن‌ها در مقیاس شهری محسوب می‌شود (Hadjidemetriou & Christodoulou, 2013; Fox et al., 2017; Fan et al., 2021).

در سال‌های اخیر، پردازش تصویر دوبعدی همراه با یادگیری ماشین به عنوان رویکردی مقرون‌به‌صرفه و عملی مورد توجه قرار گرفته است. مدل‌های کلاسیک مانند ماشین بردار پشتیبان و جنگل تصادفی و همچنین شبکه‌های عمیق مانند CNN و MobileNetV2، دقتی بین ۹۰ تا ۹۸ درصد گزارش کرده‌اند (Pawar et al., 2016; Al-Sabaei et al., 2024; Ozoglu & Gökğöz, 2023; Becker et al., 2019; Silva et al., 2020; Rufeï et al., 2022; Phan et al., 2024; Hoang, 2018). علاوه بر این، قابلیت پیاده‌سازی این

روش‌ها بر روی دوربین‌های خودرو یا تلفن‌های هوشمند، امکان استفاده از آن‌ها را در سامانه‌های پایش شهری تسهیل کرده است (Rufeï et al., 2022; Phan et al., 2024). به عنوان نمونه، (Wang et al., 2024) با ارائه مدلی ترکیبی مبتنی بر استخراج ویژگی و الگوریتم SVM، دقتی معادل ۹۵ درصد همراه با کاهش زمان پردازش نسبت به شبکه‌های عمیق گزارش کرده‌اند (Hoang, 2018). در حوزه ادغام داده‌های چندمنبعی، ترکیب تصاویر دیجیتال و حرارتی، داده‌های پهپادی و لیزری با سیگنال‌های لرزشی موجب افزایش پایداری روش‌ها در برابر تغییرات نوری و شرایط محیطی شده است (Hoang, 2018; Sathya & Saleena, 2022; Misra et al., 2024; Ahmad et al., 2024; Ling et al., 2024; Senbagavalli et al., 2025; Chawla et al., 2025; Martins et al., 2025). همچنین، بهره‌گیری از پردازش موازی مبتنی بر GPU و اتصال به زیرساخت‌های حمل و نقل هوشمند (ITS) زمینه پایش بلادرنگ و مقیاس‌پذیر را فراهم کرده است (Tamagusko et al., 2024; Vinodhini & Sidhaarth, 2023; Pawar et al., 2016). با وجود این پیشرفت‌ها، چالش‌هایی همچون کمبود پایگاه داده‌های استاندارد و برچسب‌خورده برای آموزش شبکه‌های یادگیری عمیق (Ochoa-Ruiz et al., 2020; Al-Sabaei et al., 2024)، حساسیت به تغییرات نوری و زاویه تصویربرداری، دشواری در تفکیک لکه‌ها یا وصله‌های آسفالت از چاله‌های واقعی (Pawar et al., 2016; Al-Sabaei et al., 2019; Becker et al., 2024) و نبود معیارهای ارزیابی یکپارچه (Sathya & Saleena, 2022; Misra et al., 2024; Ahmad et al., 2024) همچنان پا برجا هستند. همچنین، روش‌های سه‌بعدی با وجود دقت بالا، همچنان با پیچیدگی محاسباتی و محدودیت‌های اجرایی رو به رو هستند (Ranyal et al., 2022; Vinodhini & Sidhaarth, 2025; Fan et al., 2021; Martins et al., 2023). بر اساس تحلیل مطالعات اخیر، ترکیب رویکردهای ویژگی محور با الگوریتم‌های کلاسیک یادگیری ماشین می‌تواند تعادلی میان دقت، سرعت پردازش و مقاومت در برابر شرایط محیطی ایجاد کند (Hoang, 2018). این امر به‌ویژه با توجه به چالش نیاز به داده‌های برچسب‌خورده‌ی گسترده در یادگیری عمیق، اهمیت بیشتری می‌یابد و می‌تواند مسیر توسعه‌ی سیستم‌های چندمنظوره، مقاوم و کم‌هزینه را هموار سازد.

## ۳- روش تحقیق

در این پژوهش، دو رویکرد متفاوت برای شناسایی خرابی چاله در تصاویر دو بعدی روسازی آسفالتی توسعه داده شده است. در روش نخست، فرایند تشخیص به صورت گام به گام و مبتنی

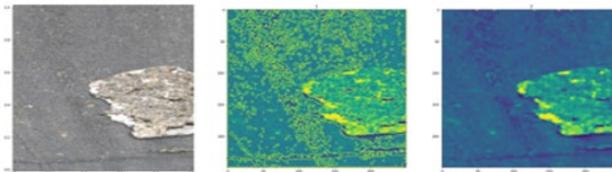
### ۳-۱- روش اول: تشخیص چاله بر اساس استخراج

#### ویژگی و ارائه الگوی طبقه‌بندی

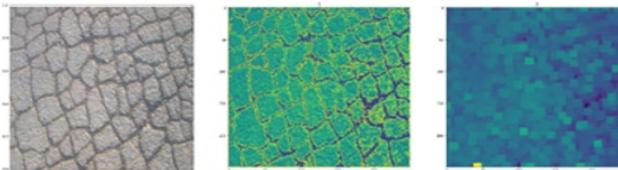
#### ۳-۱-۱- بهبود و ارتقای تصاویر

تصاویر روسازی آسفالتی تحت تأثیر عواملی همچون شرایط نوری، بازتاب سطح، لکه‌های روغن و ناهمگونی بافت قرار دارند که موجب ایجاد نویز و کاهش دقت تشخیص می‌شوند. برای رفع این چالش، مرحله‌ی پیش پردازش تصویر به منظور حذف نویز و افزایش کنتراست سطحی انجام گرفت. در این مرحله از فیلتر گوسی با انحراف معیار  $\sigma = 0.9$  و هسته‌ی  $3 \times 3$  برای کاهش نویز با فرکانس بالا استفاده شد. به منظور حذف نواحی کوچک و ناهموار و حفظ مرزهای اصلی چاله، عملیات مورفولوژیکی شامل گسترش و تحلیل با استفاده از تابع `cv2.getStructuringElement(cv2.MORPH_RECT, (3,3))` در محیط کتابخانه‌ی Open CV انجام شد. این فرآیند در دو تکرار متوالی ( $iterations = 2$ ) صورت گرفت تا تعادلی بهینه میان حذف نویز و حفظ جزئیات بافتی برقرار شود. نتایج حاصل از این مرحله نشان داد که به کارگیری فیلتر گوسی و عملیات مورفولوژیکی به طور قابل توجهی باعث افزایش وضوح مرز چاله‌ها و کاهش اثر لکه‌های سطحی شده است. شکل (۱) روند بهبود و لبه‌یابی در تصاویر چاله‌دار و بدون چاله را نشان می‌دهند.

بر پردازش کلاسیک تصویر انجام می‌شود. در این رویکرد، با اجرای مراحل لبه‌یابی، بهبود تصویر و شمارش پیکسل‌های متفاوت، نواحی دارای چاله از بخش‌های سالم تفکیک می‌گردند و در نهایت با استفاده از یک الگوریتم ساده‌ی طبقه‌بندی، تصمیم نهایی درباره‌ی وجود خرابی در تصویر اتخاذ می‌شود. در روش دوم، پس از انجام عملیات پیش‌پردازش و افزایش کیفیت تصویر، مجموعه‌ای از ویژگی‌های آماری و بافتی استخراج می‌شود. سپس این ویژگی‌ها به عنوان داده‌ی ورودی برای چند الگوریتم یادگیری ماشین (از جمله ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی و  $k$  نزدیک‌ترین همسایه) به کار می‌روند تا مدل به صورت خودکار الگوی بهینه‌ی طبقه‌بندی را بیاموزد. در پایان، پس از فرآیند آموزش و ارزیابی، سیستم قادر است تصاویر دارای خرابی چاله را با دقت بالا از تصاویر فاقد خرابی تفکیک نماید.



الف) بهبود و ارتقا تصاویر چاله دار



ب) بهبود و ارتقا تصاویر بدون چاله

شکل ۱. بهبود و ارتقا تصویر، الف) چاله دار ب) بدون چاله

### ۳-۱-۲- لبه‌یابی تصاویر

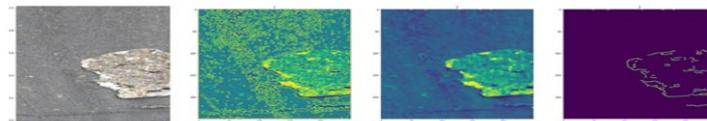
در این مرحله، هدف شناسایی مرزهای واقعی چاله‌ها از طریق تحلیل تغییرات شدت روشنایی در تصویر است. برای این منظور از توابع `cv2.findContours` و `cv2.drawContours` در کتابخانه Open CV استفاده شد.

لبه‌یابی بر پایه گرادیان شدت پیکسل‌ها انجام گرفته و برای بهبود نتایج، مجموعه‌ای از عملیات مورفولوژیکی شامل فرسایش (`cv2.erode`) و گسترش (`cv2.dilate`) به کار گرفته شد تا لبه‌های نویزی و جزئی حذف و مرز چاله‌ها تقویت گردد. در گام بعد، الگوریتم Canny با آستانه‌های پایین و بالای به‌ترتیب ۷۵ و ۱۵۰، اندازه‌ی کرنل مشتق برابر با ۳ (`apertureSize = 3`) و گزینه‌ی `L2gradient=False` اعمال شد.

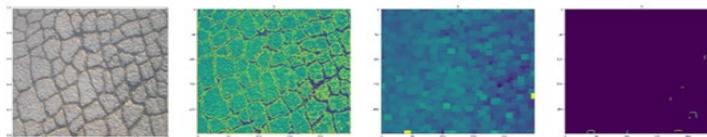
این مقادیر بر اساس ارزیابی‌های مقدماتی بر روی داده‌های آموزشی انتخاب شدند تا تعادلی میان حذف لبه‌های کاذب و حفظ مرزهای واقعی برقرار شود.

پس از استخراج لبه‌ها، به منظور حذف نواحی پراکنده و یکپارچه سازی مرز چاله‌ها، از تابع `cv2.morphologyEx` با عملگر CLOSE و کرنل مربعی  $3 \times 3$  (`cv2.getStructuringElement(cv2.MORPH_RECT, (3,3))`) استفاده گردید.

در نهایت، فرآیند بازسازی و ترسیم مرزها با به کارگیری توابع `cv2.findContours` و `cv2.drawContours` و با استفاده از روش بازیابی خارجی (`cv2.RETR_EXTERNAL`) و تقریب ساده (`cv2.CHAIN_APPROX_SIMPLE`) انجام شد. این تنظیمات بر پایه‌ی آزمون‌های مقدماتی بر روی داده‌های آموزشی تعیین گردید تا نرخ تشخیص نادرست کاهش یافته و پیوستگی مرز چاله‌ها حفظ شود. شکل (۲) نمونه‌ای از نتایج فرآیند لبه‌یابی در تصاویر را نشان می‌دهد.



الف) لبه‌یابی در تصویر چاله دار



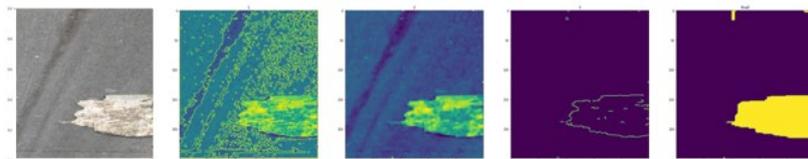
ب) لبه‌یابی در تصویر بدون چاله

شکل ۲. لبه‌یابی در تصویر الف) چاله دار، ب) بدون چاله دار

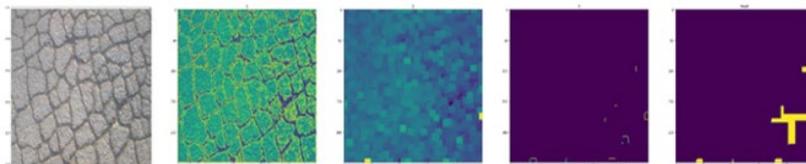
### ۳-۱-۳- استخراج ویژگی

با بهره‌گیری از ویژگی‌های مورفولوژیکی و مؤلفه‌های همبند، ناحیه چاله که توسط لبه‌ها احاطه شده و دارای بافتی ناهمگن و روشنایی متفاوت از محیط اطراف است، از تصویر تفکیک می‌شود. سپس با شمارش تعداد پیکسل‌های متمایز (عمدتاً سفید)، تصویر دارای چاله یا بدون چاله تشخیص داده می‌شود. این روش، به دلیل سادگی محاسباتی و سرعت بالا، می‌تواند به عنوان مبنایی اولیه برای مقایسه با مدل‌های پیچیده‌تر مبتنی

بر یادگیری ماشین مورد استفاده قرار گیرد. با این حال، عملکرد آن در شرایط واقعی ممکن است تحت تاثیر عواملی مانند نویز محیطی، سایه، لکه‌های سطحی و تغییرات طبیعی بافت آسفالت کاهش یابد. شکل (۳) نمونه‌ای از نتایج استخراج ویژگی را در دو حالت تصویر دارای چاله (الف) و بدون چاله (ب) نشان می‌دهد.



الف) استخراج ویژگی تصویر چاله دار



ب) استخراج ویژگی تصویر بدون چاله

شکل ۳. استخراج ویژگی تصویر، الف) چاله دار ب) بدون چاله

در شرایط واقعی، تفاوت روشنایی میان نواحی سالم و چاله دار روسازی معمولا محسوس تر از اختلاف‌های رنگی است، بنابراین بهره‌گیری از مولفه‌ی  $Y$  (درخشندگی) موجب افزایش قدرت تفکیک و پایداری مدل در برابر تغییرات جزئی نور می‌شود. یافته‌های مطالعات پیشین نیز این انتخاب را تایید می‌کنند. به عنوان نمونه، Wang et al. (2017) با استفاده از مولفه‌ی روشنایی در فضای  $YUV$ ، انرژی بافتی چاله‌ها را استخراج کرده و پایداری بالاتری در برابر تغییرات نوری گزارش کردند. همچنین، Becker et al. (2019) در پردازش تصاویر هوایی ثبت شده با پهپاد، به کارگیری فضای  $YUV$  را در کاهش اثر زاویه تابش و تغییر روشنایی موثر دانستند. افزون بر این، Ye et al. (2019) در مقایسه‌ی عملکرد مدل‌های یادگیری عمیق در فضاهای رنگی مختلف نشان دادند که فضای  $YUV$  در جداسازی نواحی آسیب دیده دقت بالاتری نسبت به فضاهای  $RGB$  و  $HSV$  ارائه می‌دهد. تفاوت محسوس در هیستوگرام کانال‌های  $U$ ،  $Y$  و  $V$  میان تصاویر دارای چاله و بدون چاله نیز موید کارایی این ویژگی‌ها در فرآیند تشخیص است. شکل (۴) نمونه‌هایی از تصاویر آسفالت چاله دار و بدون چاله را در فضای  $YUV$  و هیستوگرام مربوط به هر سه کانال نشان می‌دهد.

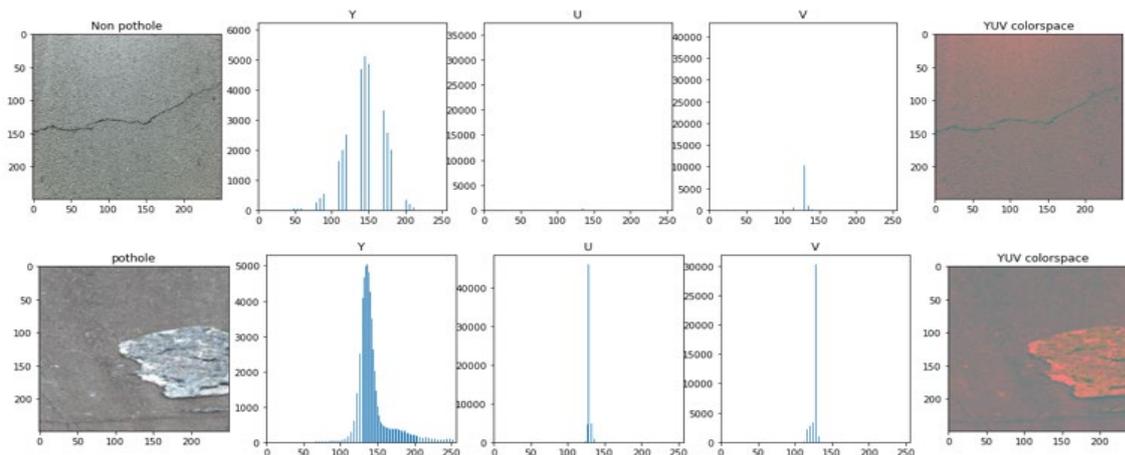
### ۳-۲- روش دوم: تشخیص چاله با استفاده از یادگیری

#### ماشین

در رویکرد مبتنی بر یادگیری ماشین، برخلاف روش ویژگی‌محور، انتخاب الگوریتم طبقه‌بندی و تنظیم پارامترهای مدل به صورت خودکار توسط سیستم یادگیرنده انجام می‌شود. در این فرآیند، ابتدا مجموعه‌ای گسترده از ویژگی‌های بصری از تصاویر، استخراج شده و سپس مدل با استفاده از داده‌های برچسب‌خورده آموزش داده می‌شود. پس از پایان مرحله آموزش، عملکرد مدل در مرحله آزمون بر اساس داده‌های جدید ارزیابی و میزان دقت و کارایی آن تعیین می‌گردد.

### ۳-۲-۱- معرفی ویژگی‌ها

ابتدا تصاویر از فضای  $RGB$  به  $YUV$  تبدیل شدند تا اطلاعات مربوط به رنگ و شدت روشنایی به صورت مجزا مورد بررسی قرار گیرند. این تبدیل موجب تفکیک بهتر ویژگی‌های مرتبط با چاله در سطح روسازی می‌شود. انتخاب فضای رنگی  $YUV$  بر این اساس انجام شد که مولفه‌ی  $Y$  بیانگر شدت روشنایی و مولفه‌های  $U$  و  $V$  نمایانگر اطلاعات رنگی هستند، از این رو، جداسازی این مولفه‌ها امکان تحلیل روشنایی و بافت سطح را به صورت مستقل از تغییرات رنگ فراهم می‌سازد.

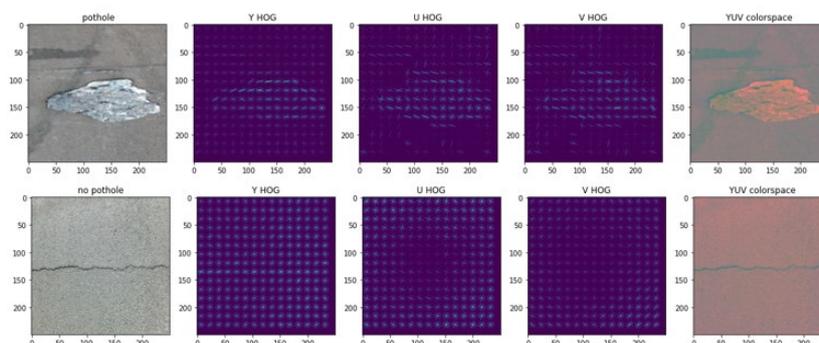


شکل ۴. نمودارهای تصویر بدون چاله (ردیف بالا) و دارای چاله (ردیف پایین) فضای رنگی YUV

### ۳-۲-۲- هیستوگرام گرادیان جهت دار (HOG)

یادگیری ماشین مورد استفاده قرار گرفته‌اند. این فرآیند موجب افزایش حساسیت مدل نسبت به الگوهای بافتی و تغییرات لبه‌ای در نواحی آسیب دیده می‌گردد. نتایج حاصل از استخراج ویژگی HOG برای هر سه کانال تصویر در فضای YUV، در شکل (۵) برای نمونه تصاویر دارای چاله و بدون چاله نمایش داده شده است.

ویژگی HOG برای استخراج اطلاعات مربوط به لبه‌ها و گوشه‌ها در تصویر به کار گرفته می‌شود. در این روش، با اندازه‌گیری تغییرات شدت روشنایی در دو جهت افقی (x) و عمودی (y)، نواحی دارای تغییرات زیاد - مانند لبه‌ی چاله‌ها - شناسایی می‌شوند (Dalal & Triggs, 2005). در پژوهش حاضر، ویژگی HOG در فضای رنگی YUV برای هر سه کانال محاسبه شده و مقادیر به دست آمده به عنوان ورودی مدل



شکل ۵. هیستوگرام تغییرات شدت تصاویر چاله دار (ردیف بالا) و بدون چاله (ردیف پایین) در فضای رنگی YUV

### ۳-۲-۳- مدل‌های یادگیری ماشین

در مطالعه حاضر، چهار الگوریتم متداول یادگیری ماشین برای طبقه‌بندی تصاویر به کار گرفته شد که عبارتند از: ماشین بردار پشتیبان (SVM) با کرنل‌های خطی، RBF و Polynomial درخت تصمیم - نزدیک‌ترین همسایه - جنگل تصادفی

مدل‌های مورد استفاده در پژوهش حاضر از نوع طبقه‌بندی کننده‌های نظارت شده هستند. در این روش‌ها، مدل ابتدا با استفاده از داده‌های برچسب‌دار آموزش می‌بیند و سپس عملکرد آن بر روی داده‌های جدید مورد ارزیابی قرار می‌گیرد.

## ۴- نتایج

### ۴-۱- نتایج روش اول

قرار گرفت. تصاویر با استفاده از دوربین تلفن همراه از ارتفاع یک تا دو متر در هوای ابری ثبت شده اند. نتایج حاصل از طبقه بندی به شرح زیر است: از میان ۵۰۰ تصویر بدون چاله، تعداد ۴۵۸ تصویر به درستی به عنوان تصویر بدون چاله تشخیص داده شد و ۷۰ تصویر به صورت اشتباه در گروه چاله دار قرار گرفت. همچنین از میان ۵۰۰ تصویر دارای چاله، تعداد ۴۳۰ تصویر به درستی شناسایی و ۴۲ تصویر به اشتباه در طبقه تصاویر بدون چاله قرار گرفتند. بر این اساس، ماتریس درهم ریختگی برای این روش به صورت زیر می باشد.

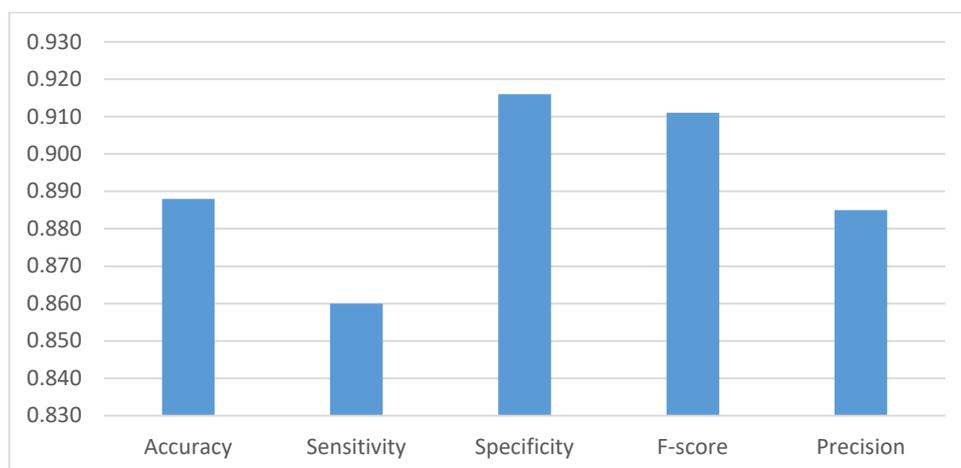
در روش تشخیص چاله مبتنی بر استخراج ویژگی های پیکسلی، وجود یا عدم وجود چاله در تصاویر روسازی آسفالتی براساس شمارش تعداد پیکسل های با رنگ متفاوت (پیکسل های سفید) انجام می شود. مقایسه این مقدار با یک آستانه از پیش تعیین شده، مبنای تصمیم گیری مدل است، به گونه ای که اگر تعداد واحدهای متفاوت از حد آستانه بیشتر باشد، تصویر به عنوان چاله شناسایی می شود. برای ارزیابی عملکرد این روش، مجموعه ای شامل ۱۰۰۰ تصویر (۵۰۰ تصویر دارای خرابی چاله و ۵۰۰ تصویر بدون چاله (شامل تصاویر آسفالت سالم و همچنین تصاویر دارای خرابی هایی غیر از چاله))، مورد بررسی

جدول ۳. نتایج حاصله شناسایی خرابی چاله در روش اول

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۴۳۰	۴۲	۴۵۸	۷۰

جدول ۴. نتایج معیار های ارزیابی حاصله از شناسایی خرابی چاله در روش اول

Accuracy	Sensitivity	Specificity	F-score	Precision
۰,۸۸۸	۰,۸۶	۰,۹۱۶	۰,۹۱۱	۰,۸۸۵



شکل ۶. نمودار میله ای معیارهای ارزیابی شناسایی خرابی چاله، روش استخراج ویژگی

#### ۴-۲- ارزیابی مدل‌ها

برای ارزیابی عملکرد مدل‌های طبقه‌بندی، از مجموعه‌ای شامل ۱۰۰۰ تصویر آموزشی استفاده شد که شامل ۵۰۰ تصویر دارای چاله و ۵۰۰ تصویر بدون چاله بود. پس از آموزش مدل‌ها، ۲۰۰ تصویر به صورت تصادفی برای مرحله تست انتخاب شدند تا عملکرد مدل‌ها در شناسایی تصاویر دارای خرابی چاله بررسی شود.

#### ۴-۲-۱- نتایج عملکرد مدل SVM با کرنل خطی

مدل ماشین بردار پشتیبان (SVM) با کرنل خطی بر روی مجموعه تست ۲۰۰ تصویری اعمال شد. نتایج نشان داد که از

میان ۱۱۰ تصویر دارای خرابی چاله، ۱۰۸ تصویر به درستی شناسایی شدند و ۲ تصویر به اشتباه به کلاس بدون خرابی اختصاص یافتند. همچنین از میان ۹۰ تصویر بدون چاله، ۸۸ تصویر به درستی شناسایی شدند و ۲ تصویر به اشتباه طبقه‌بندی شدند. بنابراین مقادیر ماتریس درهم ریختگی یا اختلاط شامل مثبت صحیح، منفی غلط، مثبت غلط و منفی صحیح به شرح جدول ۵ می‌باشد.

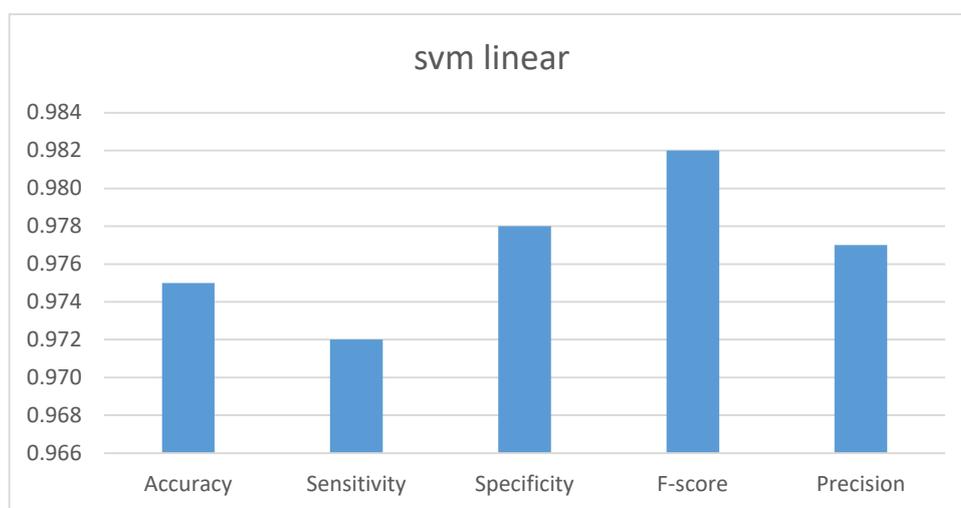
مقادیر معیارهای دقت، صحت، تشخیص پذیری، ویژگی مندی و F-score از جمله پرکاربردترین معیارها در ارزیابی عملکرد دقت مدل‌ها در مسائل دسته‌بندی و پیش‌بینی هستند، که در جدول و نمودار زیر مقادیر آنها برای مدل ماشین بردار پشتیبان (SVM) با استفاده از کرنل خطی گزارش شده است.

جدول ۵. مقادیر ماتریس درهم ریختگی روش (SVM) با استفاده از کرنل خطی

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۱۰۸	۲	۸۸	۲

جدول ۶. نتایج معیارهای ارزیابی حاصله از شناسایی خرابی چاله در طبقه‌بندی SVM با کرنل خطی

Accuracy	Sensitivity	Specificity	Precision	F-score
۰,۹۸۰	۰,۹۸۲	۰,۹۷۸	۰,۹۸۲	۰,۹۸۲



شکل ۷. نتایج معیارهای ارزیابی عملکرد طبقه‌بندی SVM با کرنل خطی به صورت نمودار میله‌ای

این نتایج بیانگر عملکرد بسیار خوب مدل SVM با کرنل خطی در طبقه‌بندی تصاویر دارای خرابی چاله است.

#### ۴-۲-۲- نتایج حاصل از طبقه‌بندی با الگوریتم ماشین بردار پشتیبان (SVM) با کرنل RBF

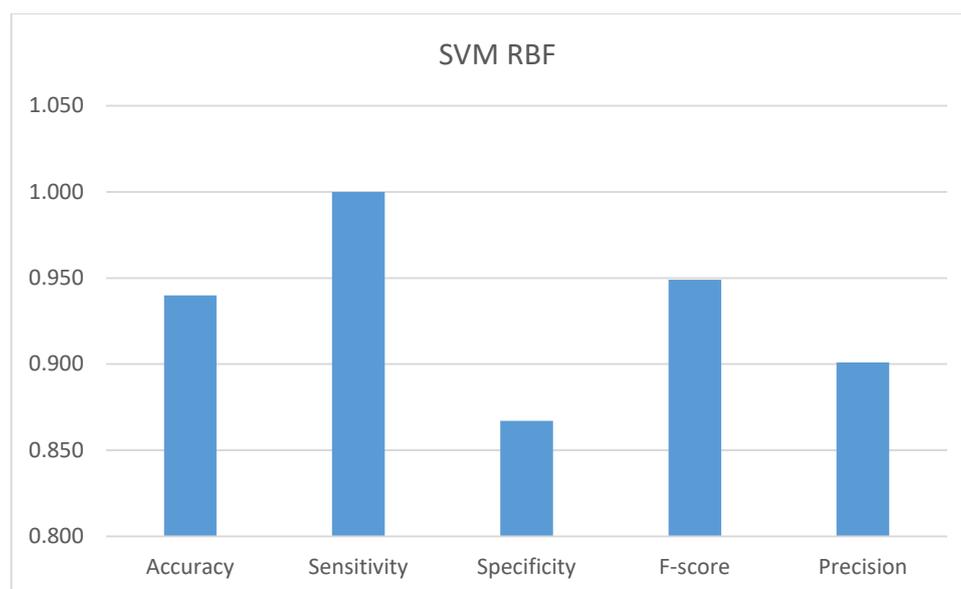
مدل SVM با کرنل شعاعی بر روی همان مجموعه تست اجرا شد. از میان ۱۲۲ تصویر دارای خرابی چاله، ۱۱۰ تصویر به درستی شناسایی شدند و ۱۲ تصویر به اشتباه طبقه بندی شدند. همچنین از میان ۷۸ تصویر بدون چاله، تمامی تصاویر به درستی شناسایی شدند.

جدول ۶. مقادیر ماتریس درهم ریختگی روش (SVM) با استفاده از کرنل RBF

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۱۱۰	۱۲	۷۸	۰

جدول ۷. نتایج معیار های ارزیابی حاصله از شناسایی خرابی چاله در طبقه بندی SVM با کرنل RBF

Accuracy	Sensitivity	Specificity	Precision	F-score
۰,۹۴۰	۱	۰,۸۶۷	۰,۹۰۱	۰,۹۴۹



شکل ۸. نتایج معیارهای ارزیابی عملکرد طبقه‌بندی SVM با کرنل RBF به صورت نمودار میله‌ای

#### ۴-۲-۳- نتایج حاصل از طبقه‌بندی با الگوریتم ماشین بردار پشتیبان (SVM) با کرنل چندجمله‌ای

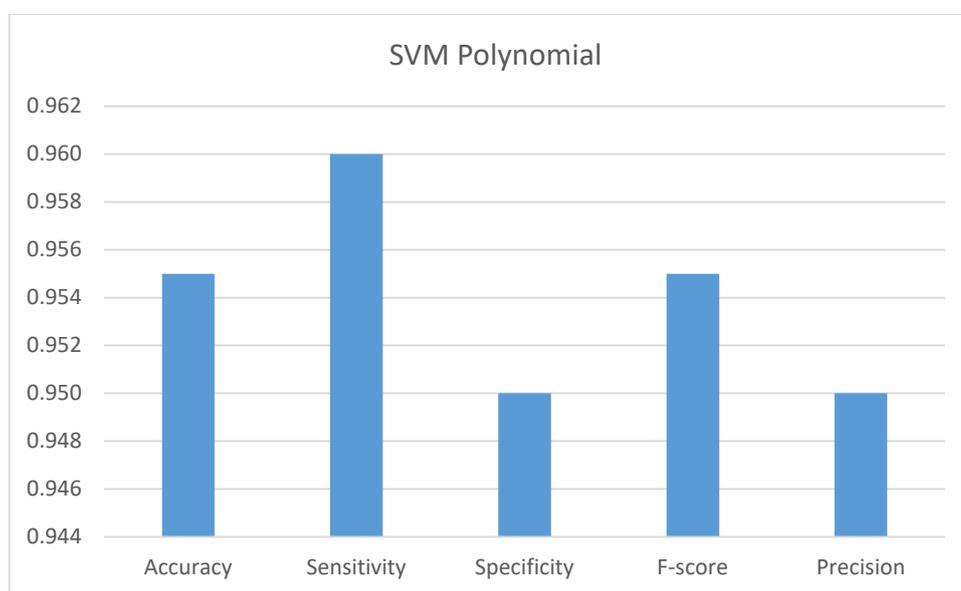
برای مدل SVM با کرنل چندجمله‌ای، از همان مجموعه تست استفاده شد. نتایج نشان داد که از میان ۱۰۰ تصویر دارای خرابی چاله، ۹۶ تصویر به درستی شناسایی شدند و ۴ تصویر به اشتباه در کلاس بدون خرابی قرار گرفتند. از میان ۱۰۰ تصویر بدون خرابی، ۹۵ تصویر به درستی شناسایی شدند و ۵ تصویر به اشتباه طبقه بندی شدند.

جدول ۸. مقادیر ماتریس درهم ریختگی روش (SVM) با استفاده از کرنل چندجمله‌ای

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۹۶	۴	۹۵	۵

جدول ۹. نتایج معیارهای ارزیابی حاصله از شناسایی خرابی چاله در طبقه‌بندی SVM با کرنل چندجمله‌ای

Accuracy	Sensitivity	Specificity	Precision	F-score
۰,۹۵۵	۰,۹۶۰	۰,۹۵۰	۰,۹۵۰	۰,۹۵۵



شکل ۹. معیارهای ارزیابی طبقه بندی SVM با کرنل چندجمله‌ای به صورت نمودار میله‌ای

۴-۲-۴- نتایج حاصل از طبقه‌بندی با الگوریتم درخت تصمیم

همچنین از میان ۱۱۰ تصویر بدون خرابی، ۹۵ تصویر به درستی شناسایی شدند و ۱۵ تصویر به اشتباه در کلاس چاله قرار گرفتند.

مدل درخت تصمیم بر روی مجموعه تست اجرا شد. از میان ۹۰ تصویر دارای خرابی چاله، ۷۷ تصویر به درستی شناسایی شدند و ۱۳ تصویر به اشتباه طبقه بندی شدند.

جدول ۱۰. مقادیر ماتریس درهم ریختگی روش درخت تصمیم

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۷۷	۱۳	۹۵	۱۵

جدول ۱۱. نتایج معیارهای ارزیابی حاصله از شناسایی خرابی چاله در طبقه‌بندی درخت تصمیم

Accuracy	Sensitivity	Specificity	Precision	F-score
۰٫۸۶۰	۰٫۸۵۵	۰٫۸۷۹	۰٫۸۳۷	۰٫۸۴۶



شکل ۱۰. نمودار میله‌ای معیارهای ارزیابی طبقه‌بندی درخت تصمیم

#### ۴-۲-۵- نتایج حاصل از طبقه‌بندی با الگوریتم جنگل تصادفی

بدون خرابی چاله، ۹۵ تصویر به درستی شناسایی شدند و ۵ تصویر به اشتباه طبقه‌بندی شدند.

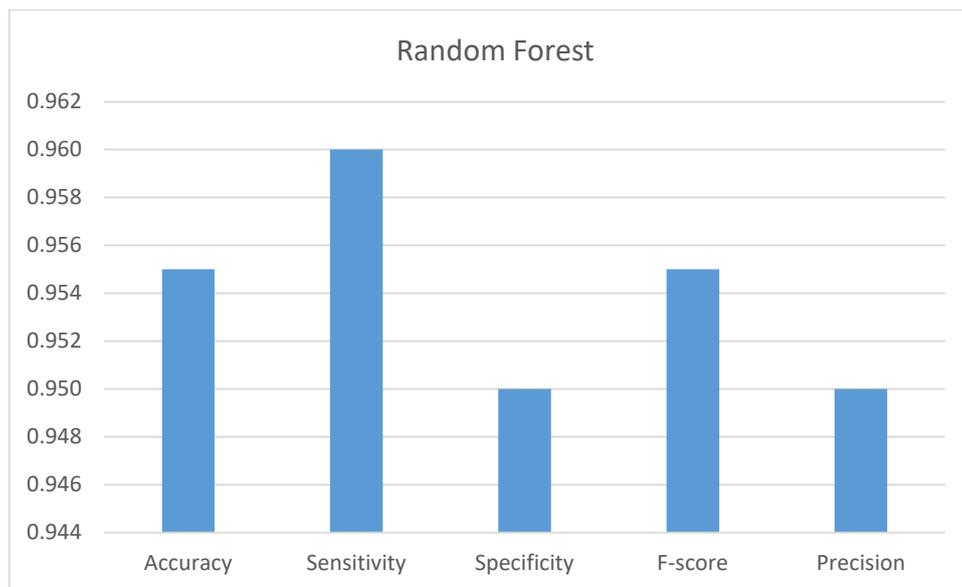
مدل جنگل تصادفی بر روی مجموعه تست اجرا شد. از میان ۱۰۰ تصویر دارای خرابی چاله، ۹۶ تصویر به درستی شناسایی شدند و ۴ تصویر به اشتباه طبقه‌بندی شدند. از میان ۱۰۰ تصویر

جدول ۱۲. مقادیر ماتریس درهم ریختگی روش جنگل تصادفی

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۹۶	۴	۹۵	۵

جدول ۱۳. نتایج معیارهای ارزیابی حاصله از شناسایی خرابی چاله در طبقه‌بندی جنگل تصادفی

Accuracy	Sensitivity	Specificity	Precision	F-score
۰٫۹۵۵	۰٫۹۶۰	۰٫۹۵۰	۰٫۹۵۰	۰٫۹۵۵



شکل ۱۱. نمودار میله‌ای معیارهای ارزیابی طبقه بندی جنگل تصادفی

#### ۴-۲-۶- نتایج حاصل از طبقه‌بندی با الگوریتم K نزدیک‌ترین همسایه

گیری و حساسیت بالای مدل نسبت به نویز می‌شوند، در حالی که مقادیر بزرگتر از  $K = 7$  باعث کاهش دقت کلی به دلیل هموارسازی بیش از حد مرزهای تصمیم‌گیری می‌گردند. براساس میانگین دقت به دست آمده در داده‌های اعتبار سنجی، مقدار  $K = 5$  به عنوان مقدار بهینه انتخاب شد، زیرا تعادل مناسبی میان پایداری و دقت مدل برقرار می‌کند. نتایج نهایی مدل KNN با مقدار بهینه  $K = 5$  در جدول (۹) ارائه شده است. دقت مدل برابر با ۹۳٫۵ درصد، حساسیت ۹۱٫۱ درصد و ویژگی مندی ۹۵٫۵ درصد به دست آمد.

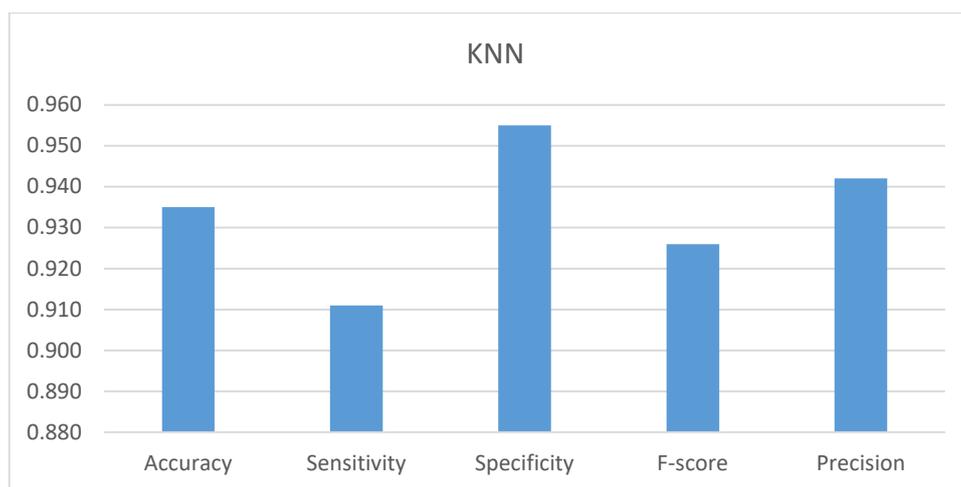
مدل KNN در این پژوهش با استفاده از معیار فاصله اقلیدسی پیاده سازی شد. این معیار به دلیل سادگی محاسباتی و پایداری بالا در داده‌های با ابعاد پایین، به عنوان متداول‌ترین روش در مدل‌های KNN شناخته می‌شود و در مطالعات پیشین نیز برای تحلیل خرابی روسازی به کار رفته است (Álvarez-García et al., 2022; Chawla et al., 2025; Ahmad et al., 2024) به منظور تعیین مقدار بهینه پارامتر K (تعداد همسایگان)، مجموعه‌ای از آزمون‌های مقدماتی در بازه  $K = 1$  تا  $K = 15$  انجام شد. نتایج این آزمون‌ها نشان داد که مقادیر کوچک‌تر از ( $K = 3$ ) موجب نوسان زیاد در تصمیم

جدول ۱۴. مقادیر ماتریس درهم ریختگی روش KNN

مثبت صحیح (True Positive)	مثبت غلط (False Positive)	منفی صحیح (True Negative)	منفی غلط (False Negative)
۸۲	۸	۱۰۵	۵

جدول ۱۵. نتایج معیارهای ارزیابی حاصله از شناسایی خرابی چاله در طبقه بندی KNN

Accuracy	Sensitivity	Specificity	Precision	F-score
۰٫۹۳۵	۰٫۹۱۱	۰٫۹۵۵	۰٫۹۴۲	۰٫۹۲۶



شکل ۱۲. نمودار میله‌ای معیارهای ارزیابی طبقه بندی KNN

### ۵- نتیجه گیری

به دلیل ماهیت غیر خطی مرز تصمیم گیری مشاهده می‌شود و ممکن است موجب افزایش نرخ مثبت کاذب گردد. با این حال، در سامانه‌های هشداردهنده، چنین عملکردی می‌تواند مطلوب باشد، زیرا کاهش خطای نوع دوم (عدم شناسایی خرابی) اهمیت ایمنی بیشتری دارد.

SVM- با کرنل چندجمله‌ای و جنگل تصادفی هر دو با دقت ۹۵٫۵ درصد عملکردی نزدیک و متعادل ارائه دادند. این مدل‌ها که بر پایه ترکیب چندین مرز تصمیم‌گیری یا مجموعه‌ای از درختان عمل می‌کنند، توانایی ارائه‌ی تعادل مناسبی میان حساسیت و ویژگی‌مندی را دارند و در شرایط عملیاتی پیچیده‌تر می‌توانند قابل اتکا باشند.

KNN- با دقت ۹۳٫۵ درصد، حساسیت ۹۱٫۱ درصد و ویژگی‌مندی ۹۵٫۵ درصد عملکردی متوسط ارائه داد. این مدل در مقایسه با درخت تصمیم کارایی بالاتری نشان داد، اما نسبت به مدل‌های مبتنی بر SVM و جنگل تصادفی ضعیف‌تر بود. دلیل این امر را می‌توان در حساسیت ذاتی KNN به نویز و وابستگی آن به نحوه توزیع داده‌ها دانست؛ به‌ویژه زمانی که داده‌های آموزشی تراکم یکنواختی ندارند.

- درخت تصمیم با دقت ۸۶ درصد، پایین‌ترین عملکرد را نشان داد. اگرچه این مدل از تفسیرپذیری بالایی برخوردار است، اما در مواجهه با ناهمگنی بافت سطح و وجود نویز محیطی، توان تصمیم‌پذیری آن کاهش می‌یابد.

همان‌گونه که در جدول ۴ نشان داده شد، روش مبتنی بر شمارش پیکسل‌ها با وجود سادگی و سرعت بالا، به دلیل حساسیت زیاد

در پژوهش حاضر، به منظور شناسایی خودکار خرابی چاله در تصاویر دوبعدی روسازی آسفالتی، چند الگوریتم یادگیری ماشین شامل ماشین بردار پشتیبان (SVM) با سه نوع کرنل (خطی، RBF و چندجمله‌ای)، درخت تصمیم، جنگل تصادفی و روش K نزدیک‌ترین همسایه (KNN) مورد ارزیابی قرار گرفت. عملکرد این روش‌ها بر اساس پنج معیار متداول شامل دقت، حساسیت، ویژگی‌مندی، دقت پیش‌بینی و F-Score تحلیل شد. نتایج به‌دست‌آمده از ارزیابی روی ۲۰۰ تصویر آزمون نشان داد:

SVM- با کرنل خطی با دستیابی به دقت ۹۸ درصد، حساسیت ۹۸٫۲ درصد، ویژگی‌مندی ۹۷٫۸ درصد و F-Score برابر با ۹۸٫۲ درصد، دقیق‌ترین و پایدارترین مدل طبقه‌بندی در این تحقیق بود. این امر نشان داد که مرزهای تصمیم‌گیری خطی برای تفکیک داده‌های این پژوهش کفایت داشته و افزایش پیچیدگی مدل لزوماً موجب بهبود عملکرد نمی‌گردد.

SVM- با کرنل RBF بالاترین حساسیت (۱۰۰ درصد) را در شناسایی تصاویر دارای چاله نشان داد، به‌گونه‌ای که تقریباً تمام نمونه‌های دارای خرابی به درستی شناسایی شدند. با این حال، کاهش ویژگی‌مندی آن به ۸۶٫۷ درصد موجب شد دقت کلی آن به ۹۴ درصد محدود شود. این موضوع بیانگر وجود یک توازن حیاتی (trade-off) میان حساسیت بالا و ویژگی‌مندی پایین‌تر است، یعنی مدل تمایل دارد تمامی نواحی دارای خرابی را شناسایی کند، حتی اگر بخشی از تصاویر سالم به اشتباه در گروه چاله‌دار قرار گیرند. چنین رفتاری معمولاً در کرنل‌های RBF

به‌کارگیری در سامانه‌های عملی تشخیص خرابی چاله است. مدل‌هایی مانند جنگل تصادفی و SVM چندجمله‌ای نیز می‌توانند در شرایط خاص عملکرد قابل قبولی داشته باشند. شایان ذکر است داده‌های این پژوهش با استفاده از دوربین تلفن همراه از ارتفاع تقریبی یک تا دو متر و در شرایط نوری ابری (سایه‌دار) ثبت شده‌اند. بنابراین، نتایج به طور مستقیم بیانگر عملکرد مدل در شرایط نوری یا زاویه‌ای متفاوت نیستند. با این حال، ارزیابی مدل‌ها در محیط‌های گوناگون می‌تواند درک عمیق‌تری از پایداری و تعمیم‌پذیری الگوریتم‌ها فراهم کند و زمینه‌سازی توسعه سامانه‌های هوشمند در آینده باشد.

به نوبت، سایه و لکه‌های سطحی آسفالت، دقت پایین‌تری (حدود ۸۸٫۸ درصد) نسبت به مدل‌های یادگیری ماشین داشته است. این نتیجه تأیید می‌کند که محدودیت اصلی این روش ناشی از وابستگی زیاد آن به شرایط نوری و کیفیت تصاویر است. به‌طور کلی، یافته‌های این پژوهش نشان می‌دهد که استفاده از تصاویر دوبعدی و الگوریتم‌های کلاسیک یادگیری ماشین مبتنی بر استخراج ویژگی می‌تواند بدون نیاز به داده‌های سه‌بعدی یا تجهیزات پرهزینه، دقت بالایی در شناسایی خرابی چاله فراهم آورد. در میان الگوریتم‌های بررسی‌شده، SVM با کرنل خطی به دلیل سادگی، پایداری و دقت بالا، مناسب‌ترین گزینه برای

## ۶-مراجع

-Chawla, K., Sharma, T., Mishra, M. K., & Mehta, D. (2025). Detecting potholes using machine learning and transfer learning models: Transforming road safety. *Communications in Computer and Information Science*, 1956.

-Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, 1, 886–893.

-Fan, R., Ozgunalp, U., Hosking, B., Liu, M., & Pitas, I. (2019). Pothole detection based on disparity transformation and road surface modeling. *IEEE Transactions on Image Processing*, 28(12), 6712–6725.

-Fan, R., Wang, H., Wang, Y., Liu, M., & Pitas, I. (2021). Graph attention layer evolves semantic segmentation for road pothole detection: A benchmark and algorithms. *IEEE Transactions on Image Processing*, 30, 8144–8154.

-Fan, R., et al. (2021). Rethinking road surface 3-D reconstruction and pothole detection: From perspective transformation to disparity map segmentation. *IEEE Transactions on Cybernetics*, 52(12), 13119–13131.

-Fox, A., Kumar, B. V. K. V., Chen, J., & Bai, F. (2017). Multi-lane pothole detection from crowdsourced undersampled vehicle sensor data. *IEEE Transactions on Mobile Computing*, 16(12), 3417–3430.

-Ahmad, C. F., Al-Sayegh, A. T., Cheema, A., Qayyum, W., Ehtisham, R., Saghira, S., & Ahmad, A. (2024). Classification of different sizes of potholes based on surface area using convolutional neural network. *Discover Applied Sciences*, 6, 207.

-Alvarez-García, J., Villavicencio, G., Altimiras, F., Crawford, B., Soto, R., Minatogawa, V., Franco, M. M. V., Martínez-Muñoz, D., & Martí, J. V. (2022). Machine learning techniques applied to construction: A hybrid bibliometric analysis of advances and future directions. *Automation in Construction*, 140, 104532.

-Al-Sabaeei, A. M., Souliman, M. I., & Jagadeesh, A. (2024). Smartphone applications for pavement condition monitoring: A review. *Construction and Building Materials*, 423, 134207.

-Aparna, Bhatia, Y., Rai, R., Gupta, V., & Aggarwal, N. (2019). Convolutional neural networks based pothole detection using thermal imaging. *Journal of King Saud University – Computer and Information Sciences*.

-Becker, Y. V. F., Siqueira, H. L., Matsubara, E. T., Gonçalves, W. N., & Marcato Jr., J. (2019). Asphalt pothole detection in UAV images using convolutional neural networks. *IGARSS 2019 – IEEE International Geoscience and Remote Sensing Symposium*, 5236–5239.

-Bradski, G. (2000). *The OpenCV library*. Dr. Dobb's Journal of Software Tools.

- Misra, M., Sharma, R., & Tiwari, S. (2024). An optimized deep belief network-based pothole detection model for asphalt road. *International Journal of Intelligent Decision Technologies*, 18(4), 761–776.
- Ochoa-Ruiz, G., Angulo-Murillo, A. A., Ochoa-Zezzatti, A., Aguilar-Lobo, L. M., Vega-Fernández, J. A., & Natraj, S. (2020). An asphalt damage dataset and detection system based on RetinaNet for road conditions assessment. *Applied Sciences*, 10(21), 7546.
- Ozoglu, F., & Gökğöz, T. (2023). Detection of road potholes by applying convolutional neural network method based on road vibration data. *Sensors*, 23(22), 9023.
- Pawar, S., Admuthé, S., Shah, M., Kulkarni, S., & Thengadi, R. (2016). Pothole detection and warning system using IBM Bluemix platform. *International Research Journal of Engineering and Technology*, 3(5), 1991–1994.
- Peraka, N. S. P., & Biligiri, K. P. (2020). Pavement asset management systems and technologies: A review. *Automation in Construction*, 119, 103336.
- Phan, T. M., Kim, J., Kim, H., & Park, D. (2024). Automated repair of asphalt pavement cracks and potholes utilizing 3D printing and LiDAR scanning. *Construction and Building Materials*, 450, 138748.
- Ranyal, E., Sadhu, A., & Jain, K. (2022). Road condition monitoring using smart sensing and artificial intelligence: A review. *Sensors*, 22(8), 3044.
- Ren, M., Zhang, X., Chen, X., Zhou, B., & Feng, Z. (2023). YOLOv5s-M: A deep learning network model for road pavement damage detection from urban street-view imagery. *International Journal of Applied Earth Observation and Geoinformation*, 121, 103335.
- Rizelioğlu, M. (2025). An extensive bibliometric analysis of pavement deterioration detection using sensors and machine learning: Trends, innovations, and future directions. *Alexandria Engineering Journal*, 112, 169–191.
- Rufei, L., Jiben, Y., Hongwei, R., Bori, C., & Chenhao, C. (2022). Research on a pavement pothole extraction method based on vehicle-borne continuous laser scanning point cloud. *Measurement Science and Technology*, 33(9), 095012.
- Safyari, Y., Mahdianpari, M., & Shiri, H. (2024). A review of vision-based pothole detection methods using computer vision and machine learning. *Sensors*, 24(17), 5652.
- Georgopoulos, A., Loizos, A., & Flouda, A. (1995). Digital image processing as a tool for pavement distress evaluation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 50(1), 23–33.
- Gonzalez, R. C., & Woods, R. E. (2018). Digital image processing (4th ed.). Pearson Education.
- Hadjidemetriou, G. M., & Christodoulou, S. E. (2013). Patch defects detection for pavement assessment using smartphones and support vector machines. *Journal of Computing in Civil Engineering*, 27(6), 664–670.
- Hoang, N.-D. (2018). An artificial intelligence method for asphalt pavement pothole detection using least squares support vector machine and neural network with steerable filter-based feature extraction. *Advances in Civil Engineering*, 2018, 7419058.
- Joy, S., Haripriya, P., & Shukla, S. (2025). Novel pothole detection system using YOLOv8 algorithm. *Proceedings of the 3rd International Conference on Communication, Security, and Artificial Intelligence (ICCSAI)*.
- Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., & Fieguth, P. (2015). A review on computer vision-based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Advanced Engineering Informatics*, 29(3), 196–210.
- Ling, M., Shi, Q., Zhao, X., Chen, W., Wei, W., Xiao, K., Yang, Z., Zhang, H., Li, S., Lu, C., & Zeng, Y. (2024). Nighttime pothole detection: A benchmark. *Electronics*, 13(19), 3790.
- Lydon, D., Taylor, S. E., Lydon, M., & Early, J. (2020). A review of vision-based methods for pothole detection and road profile analysis. *Civil Engineering Research in Ireland (CERI 2020)*.
- Lv, Z., Hao, Z., Zhu, Y., & Lu, C. (2025). A review on automated detection and identification algorithms for highway pavement distress. *Applied Sciences*, 15(11), 6112.
- Ma, N., Fan, J., Wang, W., Wu, J., Jiang, Y., Xie, L., & Fan, R. (2022). Computer vision for road imaging and pothole detection: A state-of-the-art review of systems and algorithms. *Transportation Safety and Environment*, 4(3), tdac026.
- Martins, W. D., Osório, F. S., & Bruno, D. R. (2025). Real-time deep learning-based pothole detection on low-cost embedded devices for ADAS. *Proceedings of the Brazilian Conference on Robotics (CROS)*.

- Tsai, Y.-C., & Chatterjee, A. (2017). Pothole detection and classification using 3D technology and watershed method. *Journal of Computing in Civil Engineering*, 31(4), 04017020.
- Vinodhini, K. A., & Sidhaarth, K. R. A. (2023). Pothole detection in bituminous road using CNN with transfer learning. *Measurement: Sensors*, 25, 100940.
- Wang, P., Hu, Y., Dai, Y., & Tian, M. (2017). Asphalt pavement pothole detection and segmentation based on wavelet energy field. *Mathematical Problems in Engineering*, 2017, 1604130.
- Ye, W., Jiang, W., Tong, Z., Yuan, D., & Xiao, J. (2019). Convolutional neural network for pothole detection in asphalt pavement. *Road Materials and Pavement Design*, 20(7), 1683–1703.
- Zhang, L., Shen, J., & Zhu, B. (2022). A review of the research and application of deep learning-based computer vision in structural damage detection. *Earthquake Engineering and Engineering Vibration*, 21, 1–18.
- Sathya, R., & Saleena, B. (2022). A framework for designing unsupervised pothole detection by integrating feature extraction using deep recurrent neural network. *Wireless Personal Communications*, 126(2), 1275–1292.
- Schnebele, E., Tanyu, B. F., Cervone, G., & Waters, N. (2015). Review of remote sensing methodologies for pavement management and assessment. *European Transport Research Review*, 7, 17.
- Senbagavalli, M., Mahapatra, S., Ahamed, K. H., & Ruchita, L. (2025). Revolutionizing road safety: An innovative approach to pothole detection and prevention using XAI and deep learning. *Proceedings of the 4th International Conference on Sentiment Analysis and Deep Learning (ICSADL)*.
- Silva, L. A., Sanchez, H., San Blas, D., García, D. P., Mendes, A. S., & Villarubia González, G. (2020). An architectural multi-agent system for a pavement monitoring system with pothole recognition in UAV images. *Sensors*, 20(17), 4906.
- Tamagusko, T., Correia, M. G., & Ferreira, A. (2024). Machine learning applications in road pavement management: A review, challenges and future directions. *Infrastructures*, 9(12), 213.

# Two-Dimensional Image Processing for Automated Detection of Potholes in Asphalt Pavements A Comparative Analysis of Feature-Based and Machine Learning Approaches

*Mohammad Ali Tabeei, Ph.D., Student, School of Civil Engineering, Iran University of Science and Technology (IUST), Tehran, Iran.*

*Hossein Alinegadiyan, Ph.D., Student, Faculty of Civil Engineering, Shahrood University of Technology, Semnan, Iran.*

*Barat Mojaradi, Associate Professor, Department of Civil Engineering, Iran University of Science and Technology (IUST), Tehran, Iran.*

*Mahmood Ameri, Professor, Department of Civil Engineering, Iran University of Science and Technology (IUST), Tehran, Iran.*

**E-mail: [tabeei.mohammadali1994@gmail.com](mailto:tabeei.mohammadali1994@gmail.com)**

Received: September 2025- Accepted: February 2026

## ABSTRACT

Accurate and timely detection of pavement distresses plays a vital role in maintaining the safety and durability of asphalt pavements. Traditional inspection methods, such as visual surveys, suffer from limitations including human error, high cost, and lack of repeatability. In this study, two distinct approaches—feature-based image processing and machine learning—were employed and compared to automatically detect potholes in asphalt pavements from two-dimensional images. A dataset consisting of pothole and non-pothole images was collected, preprocessed, and used for feature extraction. Subsequently, several classification algorithms, including Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Decision Tree, and Random Forest, were trained and evaluated. Model evaluation results indicated that the linear-kernel SVM achieved superior performance, with an accuracy exceeding 97% in distinguishing pothole images from intact surfaces. Despite its computational simplicity, the proposed approach demonstrated high accuracy and satisfactory efficiency compared with traditional methods, under controlled lighting (overcast conditions) and a fixed imaging angle. This method can serve as a practical and cost-effective alternative to visual inspection in pavement maintenance management.

**Keywords:** Pavement Distress Detection, Image Processing, Feature Extraction, Machine Learning