



شناسایی عیب عایق های خطوط انتقال برق بر اساس مدل بهبودیافته شبکه سبک وزن با کمک بینایی کامپیوتری

سید مجید کشاورز^{۱*} پویاعلم چشمه جناار^۱

گروه مهندسی برق دانشگاه فنی حرفه ای، یاسوج، واحد پسران، ایران،

^۱ Skeshavarz.tvu@ac.ir. ^۲ Poyaalam8000@gmail.com

چکیده

هدف این کار اطمینان از عملکرد ایمن خطوط انتقال برق و کاهش هزینه ها و مشکلات نگهداری است. به بررسی کاربرد بینایی کامپیوتری (CV) در شناسایی نقص خطوط انتقال برق می پردازد. علاوه بر این، این کار روشی را برای بهبود مدل شبکه سبک وزن برای ارائه یک مدل شناسایی موثر برای حل مشکل نقص خط انتقال برق پیشنهاد می کند. در مرحله اول، الگوریتم های تقسیم بندی GraphCut و لاپلاس برای گسترش و وضوح تصویر خط انتقال الکتریسیته استفاده می شوند. ثانیاً، با توجه به الگوریتم پیچیدگی قابل جداسازی عمق، یک مدل تشخیص عیب برای عایق خط انتقال برق بر اساس شبکه (You Only Look Once) 4YOLOv پیشنهاد شده است. علاوه بر این، 1MobileNetV برای بهبود این مدل شبکه سبک وزن استفاده می شود. در نهایت، این کار از ImageNet، یک مجموعه داده عمومی بزرگ، برای اعتبارسنجی آزمایشی مدل پیشنهادی استفاده می کند. نتایج تحقیق نشان می دهد که: (1) در نتایج آزمایش مدل، همه شاخص های تحقیقاتی مدل بیشتر از 90 درصد هستند که نشان دهنده دقت تشخیص عالی این مدل است. (2) مدل بهبودیافته 4YOLOv می تواند سرعت تشخیص را تا 53 فریم بر ثانیه با هزینه 2.4 درصد دقت افزایش دهد. (3) پس از وضوح تصویر، مدل بهبود یافته 4YOLOv توانایی تشخیص عیوب عایق را تا حد معینی ارتقا داده است. نتایج فوق نشان می دهد که مدل بهبود یافته 4YOLOv می تواند کارآمدتر و دقیق تر پیش بینی کند و موارد مثبت کاذب غیرضروری را کاهش دهد. این نشان می دهد که مدل پیشنهادی امکان پذیر است و انتظار می رود در عمل برای شناسایی نقص خطوط انتقال برق اعمال شود. این یافته ها به طور کامل ارزش حیاتی این کار را در افزایش کارایی و دقت پیش بینی نشان می دهد، بنابراین ترجیح قوی برای شناسایی نقص خطوط انتقال برق در کاربردهای عملی ارائه می دهد.

کلمات کلیدی: بینایی کامپیوتری شبکه سبک وزن پیچیدگی قابل تفکیک نمودار برش تقسیم بندی عایق خط انتقال برق

1- مقدمه

بازرسی تجهیزات انتقال عمدتاً شامل روش‌هایی مانند کار دستی، هلیکوپتر، وسایل نقلیه هوایی بدون سرنشین (پهپاد)، روبات‌ها و نظارت آنلاین است. تحت شرایط خاص آب و هوایی و موقعیت مکانی، تشخیص خطاهای خط از طریق بازرسی های دستی دشوار است و کارایی بازرسی های دستی نسبتاً پایین است [1، 2]. بازرسی هلیکوپتر دارای مشکلاتی مانند مصرف زیاد منابع، ریسک شخصی بالا، الزامات فنی بالا و کنترل ارتفاع بالا است. نمی تواند الزامات بازرسی را در سطوح مختلف ولتاژ، شرایط جغرافیایی و شرایط خاص هواشناسی برآورده کند. فناوری های هلیکوپتر، پهپاد، نظارت آنلاین و بازرسی ربات می توانند داده های تصویری نور مرئی، مادون قرمز و فرابنفش خطوط انتقال نیرو و اجزای برق کمکی آنها را به دست آورند و تشخیص وضعیت را انجام دهند. آنها مزایای کم هزینه، راندمان بالا، عملی بودن قوی و عملکرد انعطاف پذیر را دارند و به تدریج به یک ابزار ضروری برای بازرسی قدرت تبدیل شده اند. با این حال، روش های بازرسی فوق تعداد زیادی تصویر و فیلم تولید می کند. تنها اتکا به بازرسان برای قضاوت بصری می تواند به ناچار منجر به راندمان پایین و قضاوت نادرست آسان شود. تشخیص هدف و تشخیص تصویر در بینایی کامپیوتری (CV) می تواند نیازهای پردازش، تجزیه و تحلیل و تشخیص هوشمندانه بسیاری از تصاویر بازرسی را برآورده کند. آنها می توانند ابزارهای فنی را برای پرسنل عملیات شبکه برق و تعمیر و نگهداری فراهم کنند تا به طور هوشمند تصاویر بازرسی تجهیزات انتقال را تجزیه و تحلیل و شناسایی کنند [3]. فناوری CV مزایای قابل توجهی را در بازرسی تجهیزات انتقال نشان می دهد. این می تواند به طور موثر داده های تصویر عظیم را پردازش کند، نقاط خطا را به دقت شناسایی کند، کارایی بازرسی را بهبود بخشد و نرخ قضاوت نادرست را کاهش دهد [4]. در مقایسه با روش های بازرسی سنتی، CV هوشمندتر و کارآمدتر است، به اطمینان از عملکرد ایمن و پایدار شبکه برق کمک می کند و کمکی حیاتی برای توسعه صنعت برق است.

در حال حاضر، ادغام فناوری بینایی کامپیوتر (CV) برای ارزیابی وضعیت ساختارهای خطوط انتقال برق و اجزای مرتبط با آنها به کاربرد عملی تبدیل شده است. با این حال، چندین چالش وجود دارد: (1) مجموعه داده های آموزشی مدل نامتعادل است [5]. استفاده از مدل های یادگیری عمیق (DL) برای تشخیص عیب، به داده های تصویر برجسب دار عظیمی نیاز دارد تا یک مدل تشخیص با دقت بالا و قوی آموزش داده شود. با این وجود، سناریوهای عملی اغلب فاقد نمونه های نقص کافی برای برآوردن شرایط آموزشی مدل های تشخیص هوشمند هستند. (2) قابلیت اطمینان مدل در محیط های پیچیده کاهش می یابد. محیط اطراف کانال انتقال دارای تنوع قابل توجهی است و پس زمینه تصویر گشت زنی در فصول، آب و هوا، زمان عکس برداری و زوایای مختلف متفاوت است. مدل های موجود فاقد قابلیت کاربرد جهانی برای تشخیص هدف در میان تصاویر پس زمینه متفاوت [6] هستند. (3) عملکرد بیدرنگ تشخیص مدل کمتر از حد مطلوب باقی می ماند. تصاویر پهپادها و ربات های دارای دوربین باید برای تجزیه و تحلیل به یک سرور متمرکز منتقل شوند. اپراتور وظیفه اقدامات عملیاتی و نگهداری مربوطه را با توجه به نتایج شناسایی انجام می دهد. منابع ارتباطی و قابلیت های محاسبات لبه به طور کامل مورد استفاده قرار نمی گیرند، که نمی تواند نیازهای بلادرنگ را برآورده کند [7]. در نتیجه، آموزش مدل های DL با دقت بالا و قابلیت های تعمیم قوی در محیط هایی که با نمونه های نامتعادل مشخص می شوند، چالش بزرگی برای تشخیص هوشمند تصویر در بازرسی تجهیزات انتقال باقی می ماند. علاوه بر این، ادغام موثر محاسبات لبه با مدل های DL به عنوان یک تمرکز تحقیقاتی مهم در حوزه فناوری اینترنت اشیاء قدرتمند ظاهر شده است.

طور خلاصه، این کار به روش های ساخت و بهبود مدل های تشخیص هدف مبتنی بر DL که بر اساس سناریوهای تشخیص عیب معمولی در خط انتقال الکتریسیته است، می پردازد. علاوه بر این، با توجه به چالش های ذکر شده، تلاش های بهینه سازی

در ابعاد مختلف از جمله ورودی مدل، نمونه‌های تصویر، شبکه‌های استخراج ویژگی، شبکه‌های فیوژن ویژگی، و خروجی مدل انجام می‌شود. هدف کلی بهبود دقت، سرعت و توانایی تعمیم مدل تشخیص هدف است، بنابراین بازرس شبکه قدرت را در ارزیابی وضعیت خطوط انتقال برق تسهیل می‌کند.

برای پرداختن به چالش‌های فوق، فناوری CV معرفی می‌شود و یک مدل شبکه سبک وزن بهبود یافته برای شناسایی نقص خط انتقال برق با هدف ارائه یک مدل شناسایی کارآمد پیشنهاد می‌شود. در این کار، تکنیک‌های بهبود و شارپ کردن تصویر برای بهبود مدل شبکه مبتنی بر 4YOLOv از طریق الگوریتم Depth Separable Convolution (DSC) استفاده می‌شود و مدل شبکه سبک وزن با استفاده از 1MobileNetV بهینه شده است. در میان آنها، این یک نوع عملیات کانولوشن است که در آن فرآیند پیچش به دو مرحله تقسیم می‌شود: پیچیدگی عمیق (DC) و پیچیدگی نقطه ای (PC). در مرحله DC، هر کانال ورودی با هسته کانولوشن مربوطه در هم می‌پیچد، که می‌تواند اطلاعات ویژگی‌های هر کانال را بدون افزایش تعداد پارامترهای مدل استخراج کند. هدف از این مرحله ثبت جزئیات تصویر ورودی با اعمال فیلتر فضایی برای هر کانال است. از طریق تأیید آزمایشی روی مجموعه داده عمومی در مقیاس بزرگ ImageNet، این کار عملکرد نوآورانه مدل را در تشخیص عیب عایق نشان می‌دهد که به تشخیص با دقت بالا دست می‌یابد و سرعت تشخیص را با موفقیت بهبود می‌بخشد. در عین حال، توانایی مدل در تشخیص عیوب عایق نیز پس از شارپ کردن تصویر افزایش می‌یابد. این نوآوری‌ها سهم منحصر به فرد این کار را در بهبود کارایی و دقت پیش‌بینی‌ها، ارائه راه‌حل‌های قابل اجرا و خلاصه برای مشکلات شناسایی نقص خطوط انتقال برق در کاربردهای دنیای واقعی، برجسته می‌کنند.

2- ادبیات و پیشینه تحقیق

با پیشرفت مستمر سخت افزار واحد پردازش گرافیکی (GPU)، فناوری CV به طور فزاینده ای در تشخیص عایق استفاده می‌شود. تصاویر عایق را می‌توان توسط پهپادها یا دوربین‌ها برای به دست آوردن یک مجموعه تصویر گرفت [8]. الگوریتم‌های یادگیری ماشین (ML) را می‌توان برای دستیابی به محلی سازی عایق و تشخیص عیب عایق در خطوط انتقال برق استفاده کرد [9]. روش‌های تحقیق فعلی برای تشخیص عایق را می‌توان به سه دسته طبقه بندی کرد: پردازش تصویر سنتی، الگوریتم‌های تشخیص ML و DL [10، 11]

روش سنتی پردازش تصویر که برای تشخیص عایق در خطوط انتقال الکتریسیته استفاده می‌شود، معمولاً عایق را از پس‌زمینه پیچیده با ویژگی‌های رنگ تصویر و سطح خاکستری تقسیم می‌کند و تشخیص عیب را با الگوریتم‌ها محقق می‌کند. پاکت و همکاران (2021) روش تقسیم‌بندی مدل کانتور فعال سنتی را از طریق ویژگی‌های توزیع فضایی بهبود بخشید و آن را برای تشخیص عایق اعمال کرد [12]. می و همکاران (2021) از الگوریتم OTSU و الگوریتم کلونی مورچه‌ها برای قطعه بندی و استخراج عایق‌ها در تصویر استفاده کرد و با اندازه گیری فاصله بین عایق‌های مجاور، محل عیوب عایق را تعیین کرد [13]. خلیل و همکاران (2022) یک روش تشخیص مبتنی بر دید خودکار را پیشنهاد کرد که نقش حیاتی فناوری‌ها و روش‌های نوظهور را در نگهداری و قابلیت اطمینان سیستم قدرت برجسته می‌کند. این تحقیق تصاویر پهپاد، فناوری دید خودکار و یک مدل DL بهبود یافته را برای ارائه راه‌حل‌های نوآورانه برای تعیین موقعیت دقیق، تشخیص و نگهداری عایق‌های خطوط انتقال برق و تجهیزات مرتبط با آن، ترکیب کرد، بنابراین قابلیت اطمینان و ایمنی سیستم قدرت را بهبود بخشید [14]. با رواج تدریجی هوش مصنوعی، استفاده از روش ML برای تشخیص عایق تبدیل به یک روند شد. کیو و همکاران (2022) مدل DL از 4YOLOv سبک وزن بهبود یافته را پذیرفت و از آن برای تشخیص عیوب عایق استفاده کرد. نتایج نشان داد که این روش می‌تواند به دقت، فراخوانی و امتیاز 1F در تشخیص عیب عایق دست یابد. این تحقیق برای قابلیت اطمینان و امنیت سیستم

های قدرت اهمیت زیادی داشت و منابع تحقیقاتی و کاربردی ارزشمندی را برای زمینه های مرتبط ارائه کرد [15]. جیانگ و همکاران (2022) ویژگی های بافت بهینه شده را برای نمایش تصاویر عایق انتخاب کردند و اطلاعات موقعیت عایق را از طریق تصاویر پیش بینی شده جستجو کردند [16]

لیو و همکاران (2021) الگوریتم تشخیص گوشه هریس را هم برای تصویر هدف و هم برای تصویر الگو اعمال کرد و اطلاعات ویژگی را با اطلاعات ویژگی الگو مطابقت داد. با این حال، تصاویر به تغییرات مقیاس حساس و مستعد تطابق اشتباه بودند، که تشخیص عایق ها در پس زمینه های پیچیده را دشوار می کرد [17]. توسعه سریع فناوری سخت افزار GPU به طور قابل توجهی زمان محاسبات DL را کوتاه کرد و به کاربرد فناوری DL در تشخیص اشیاء سه بعدی پی برد. پنگ و همکاران (2021) از یک مدل شبکه عصبی از پیش آموزش دیده برای استخراج ویژگی های خارجی عایق ها، به دنبال تقسیم بندی سوپرپیکسلی و عملیات تشخیص ناحیه برای ساخت لایه خروجی استفاده کرد و در نهایت به تشخیص نقص عایق دست یافت [18]. دنگ و همکاران (2022) از الگوریتم Single Shot MultiBox Detector (SSD) به عنوان چارچوب اصلی برای تشخیص ویژگی استفاده کرد و تشخیص ویژگی را در دو مرحله انجام داد. در ابتدا، این مدل برای استخراج ویژگی اولیه اعمال شد. سپس با استفاده از تصاویر با پس زمینه و تداخل های مختلف، مدل تنظیم شد. این رویکرد به طور قابل توجهی کارایی تشخیص عایق را ارتقا داد [19]. یی و همکاران (2022) یک روش تشخیص عایق هوشمند مبتنی بر شبکه های عصبی کانولوشن پیشنهاد کرد. موقعیت یابی مقرر ابتدا انجام شد و به دنبال آن مقایسه مستمر عایق ها در تصاویر مختلف در داخل شبکه و شناسایی ویژگی های نقص عایق انجام شد، در نتیجه تشخیص عیب عایق در پس زمینه های پیچیده [20] انجام شد. وانگ و همکاران (2020) یک سیستم نظارت بر یخ خط انتقال بالای سربار مبتنی بر هوش لبه را ساخت و یک روش تشخیص بصری سبک وزن را بر اساس هرس کانال مبتنی بر تبعیض برای پایانه های نظارت بر یخ با منابع محاسباتی محدود پیشنهاد کرد. نتایج تجربی نشان داد که این روش به دقت 74.5 درصد در تشخیص تصویر یخ در شرایط آب و هوایی شدید، با اندازه مدل کوچک مناسب برای پایانه های نظارت با محدودیت منابع [21] دست یافت. فنگ و همکاران (2023) به چالش های مدیریت ریسک در عملیات سیستم قدرت پرداخته و روشی را برای شناسایی پیوندهای حیاتی در عملیات قدرت بر اساس شبکه های عصبی کانولوشن هیبریدی مکانی-زمانی پیشنهاد کرده است. نتایج تجربی نشان داد که این روش می تواند انواع مختلفی از لینک های عملیات برق و زمان شروع و پایان آنها را با عملکرد بالاتر از خوب به دقت شناسایی کند. دقت متوسط تا 87.8 درصد، با نرخ فریم 61 فریم در ثانیه بود که برای بهبود روش های کنترل عملیات ایمنی قدرت اهمیت زیادی داشت [22]

به طور خلاصه، روش های سنتی تشخیص پردازش تصویر عمدتاً به اطلاعات رنگ و بافت به عنوان مقادیر ویژگی متکی هستند. با این حال، هنگامی که برج های قطب و تیرهای سیم با رنگ های مشابه در پس زمینه رشته های مقرر وجود دارد، دقت شناسایی الگوریتم کاهش می یابد. علاوه بر این، ML در درجه اول موقعیت اشیاء هدف را با انتخاب مقادیر ویژگی مناسب و ساخت مدل های تشخیص شناسایی می کند، اما این روش اغلب به محاسبات گسترده نیاز دارد و فرآیند محاسبات بسیار دشوار است. در مقابل، تشخیص DL به دسته یادگیری نظارت شده تعلق دارد و می تواند تداخل پس زمینه های پیچیده در تصاویر را نادیده بگیرد. این باعث می شود که فناوری DL برای تشخیص عیب از طریق عکس های هوایی مقرر ها بسیار مناسب باشد. با این وجود، بسیاری از اشیاء هدف و اندازه های تصویر بسیار بزرگ در تصاویر وجود دارد که مستقیماً بر کارایی شبکه های عصبی تأثیر می گذارد. این الزامات برای تجزیه و تحلیل تصویر، دشواری تشخیص عیب عایق هوشمند را بیشتر می کند. نوآوری این کار در معرفی فناوری CV، به کارگیری مدل های بهبود یافته شبکه سبک وزن برای شناسایی عیب عایق در عایق های خطوط انتقال برق نهفته است. عملکرد مدل از طریق تکنیک های بهبود تصویر و وضوح بهبود می یابد و بهینه سازی بر

اساس شبکه 4YOLOv و 1MobileNetV انجام می‌شود. نتایج تجربی نشان می‌دهد که این مدل دقت بالایی در تشخیص عیب عایق از خود نشان می‌دهد، در حالی که سرعت تشخیص را بدون کاهش دقت بهبود می‌بخشد، و توانایی خود را برای دستیابی به تعادل بین کارایی و دقت مدل نشان می‌دهد. در مقایسه با روش‌های دیگر، این کار بیشتر بر روی ثبت ویژگی‌های دقیق و برآورده کردن الزامات کاربردی کاربردی از طریق بهینه‌سازی مدل‌های شبکه سبک تمرکز دارد. بنابراین، در مقایسه با تحقیقات قبلی، این کار بر ترکیبی از کارایی و دقت تمرکز دارد، که نوآوری بیشتر و ارزش اکتشاف عملی را در رسیدگی به عیوب عایق نشان می‌دهد.

3- مبانی نظری و استقرار مدل

1-3 مجموعه داده تصویر و پیش پردازش عایق های خطوط انتقال برق

تقویت تصویر مبتنی بر تقسیم بندی GraphCut


تصاویری که در طول بازرسی تجهیزات انتقال به دست می‌آیند، اغلب تغییرات قابل توجهی در زوایای عکاسی، نور ناهموار و پس‌زمینه‌های پیچیده را نشان می‌دهند. برای گسترش نمونه‌های تصویر مورد استفاده برای DL، الگوریتم تقسیم‌بندی GraphCut برای استخراج اهداف عایق معیوب استفاده می‌شود. این اهداف با تصاویر پس‌زمینه محیط‌های واقعی اطراف خطوط انتقال برق ترکیب می‌شوند که می‌تواند تصویر ترکیبی جدیدی از عایق‌های معیوب ایجاد کند و نمونه‌ها را گسترش دهد [23]

الگوریتم تقسیم بندی GraphCut تابع انرژی $E(x)$ را اعمال می کند تا تصمیم بگیرد که آیا هر پیکسل در تصویر پیش زمینه یا پس زمینه است [24]. یک تصویر به صورت $G=(X, Y)$ تنظیم می شود. X تمام گره های پیکسل را در تصویر نشان می دهد. Y به لبه های اتصال بین گره ها اشاره دارد. برای هر گره i ، اگر هدف پیش‌زمینه باشد، $1 \times i =$ اگر پس‌زمینه باشد، $0 \times i =$. تابع انرژی تقسیم‌بندی تصویر در رابطه (1) نشان داده شده است :

$$E(x) = \sum_{i \in X} E_1(X_i) + \lambda \sum_{i,j \in Y} E_2(x_i, x_j) \quad (1)$$

$1E$ نشان دهنده انرژی مصرف شده هنگام تعیین پیش زمینه یا پس زمینه گره i است. $2E$ انرژی مصرف شده را هنگامی که دو گره مجاور متفاوت هستند نشان می دهد A . به پارامتر تعادل انرژی اشاره دارد که معمولاً 50 تنظیم می شود. این تجربه نشان داده است که این مقدار می تواند نتایج بهتری در بسیاری از مشکلات تقسیم بندی تصویر ایجاد کند. مشاهدات تجربی نشان می دهد که این مقدار خاص اغلب با ایجاد تعادل بین وزن گره و عملکرد هموارسازی انرژی، نتایج برتر را به همراه دارد. از این رو، الگوریتم می تواند ویژگی های پیکسل و رابطه بین پیکسل های همسایه را در نظر بگیرد. سپس از الگوریتم حداکثر جریان برای به دست آوردن حداقل مقدار $E(x)$ استفاده می شود و به تقسیم بندی عایق ها در تصویر دست می یابد. متعاقباً، ادغام اهداف عایق تقسیم‌بندی شده با تصاویر پس‌زمینه واقعی خطوط انتقال برق، گامی حیاتی در تولید نمونه‌های جدید تصویر مقرر معیوب است. الگوریتم حداکثر جریان یک الگوریتم تئوری گراف است که برای یافتن مسیر حداکثر جریان از یک گره منبع به یک گره سینک در یک شبکه استفاده می شود. در این مشکل، هر لبه دارای وزنی است که حداکثر جریان ظرفیت آن را نشان می دهد. هدف الگوریتم حداکثر جریان یافتن حداکثر مسیر جریان از طریق شبکه است و می تواند به حل

مسائل مختلف کاربردی مانند بهینه سازی جریان شبکه و زمان بندی وظایف کمک کند. الگوریتم‌های حداکثر جریان معمولی شامل الگوریتم‌های فورد-فولکرسون و ادموندز-کارپ هستند. شکل 1a و b یک نمودار تقسیم بندی را نشان می دهد.



2-3 تیز کردن لاپلاس

پیچیدگی پس زمینه اطراف خطوط انتقال الکتریسیته اغلب می تواند باعث شود که اهداف عایق رنگ‌هایی شبیه به پس زمینه نشان دهند. ممکن است کمتر از پس زمینه روی لبه و کلی قابل تشخیص باشد. روش شارپنس لاپلاسی برای تقویت تصویر برای رفع این مشکل استفاده می شود. هدف آن تاکید بر جزئیات لبه هدف در تصویر و افزایش کنتراست است. تبدیل لاپلاس تصویر عایق باینری $f(x,y)$ به شرح زیر است.

$$\nabla^2 f(x,y) = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (2)$$

محاسبه تمایز جزئی مرتبه دوم تصویر باینری $f(x,y)$ در x,y جهت ها در معادلات (3) و (4) نشان داده شده است.

$$\frac{\partial^2 f}{\partial x^2} = f(x+1,y) + f(x-1,y) - 2f(x,y) \quad (3)$$

$$\frac{\partial^2 f}{\partial y^2} = f(x,y+1) + f(x,y-1) - 2f(x,y) \quad (4)$$

ضروری است که معادلات (3)، (4) را با معادله (2) جایگزین کنیم و عملگر لاپلاس:

$$\nabla^2 f(x,y) = f(x+1,y) + f(x-1,y) + f(x,y+1) + f(x,y-1) - 4f(x,y) \quad (5)$$

در رابطه (5)، فیلتر تیز کننده $[0, 1, 0; 1, 4, -1; 0, 1, 0]$. این فیلتر با استفاده از استاد کار هنری برای عملیات کانولوشن اعمال می شود. سپس می توان تصویر لاپلاس را استخراج کرد. در مرحله بعد، با پوشاندن استاد کار با تصویر لاپلاس مطابق با رابطه (6)، می توان تصویر عایق $g(x,y)$ تیز شده را به دست آورد. در اینجا استاد کار هنری تصویر مرجع را نشان می دهد که معمولاً به عنوان مقایسه یا نقطه مرجع در پردازش تصویر، CV یا آزمایش ها استفاده می شود. تصویر مرجع می تواند یک تصویر استاندارد باشد که برای ارزیابی عملکرد یا اثربخشی الگوریتم ها استفاده می شود، یا می تواند تصویر مرجعی باشد که به عنوان

داده ورودی برای مقایسه یا دستکاری با تصاویر دیگر استفاده می شود. در پردازش تصویر، تصویر مرجع اغلب به عنوان یک الگو یا مرجع برای کمک به تجزیه و تحلیل، بهبود یا اصلاح سایر تصاویر استفاده می شود. در طراحی آزمایشی، تصویر مرجع معمولاً برای کالیبراسیون اندازه گیری ها، تشخیص تغییرات یا اعتبارسنجی نتایج استفاده می شود. با مقایسه با تصویر مرجع، تغییرات یا اثرات در فرآیند پردازش تصویر را می توان بهتر درک کرد.

$$g(x, y) = f(x, y) - \nabla^2 f(x, y) \quad (6)$$

شکل 2: a و b مقایسه اثرات قبل و بعد از تیز کردن را نشان می دهد.



شکل 2: نمودار شماتیک اثر شارپنس لاپلاسی (الف) تصویر قبل از شارپنینگ. (ب) تصویر تیز شده

شکل 2 نشان می دهد که تصویر شارپ شده می تواند کنتراست کلی و محلی را با کارایی بالا بهبود بخشد و می تواند تاثیر تاری و اتمیزه شدن تصویر را اندکی کاهش دهد [25].

3-4 مجموعه داده تصویر عایق برای خطوط انتقال برق

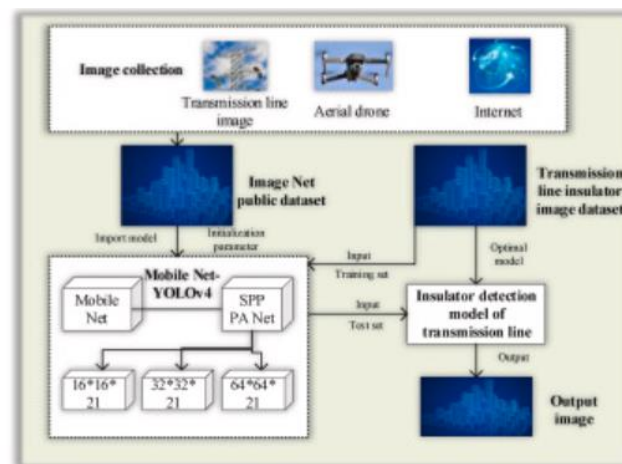
تصاویر عایق مورد استفاده در اینجا تا حدی از مجموعه داده عایق خط برق چین که به صورت آنلاین منتشر شده است به دست آمده است. این مجموعه داده شامل 600 تصویر عایق معمولی و 248 تصویر عایق معیوب است. علاوه بر این، 216 تصویر از عکس های هوایی گرفته شده در حین گشت زنی پهپاد استخراج شده است. سایر تصاویر از تقویت تصویر بر اساس تقسیم بندی GraphCut مشتق شده اند. این فرآیند تقویت، تصاویر عایق مجازی را تولید می کند، که همراه با تصاویر واقعی عایق از مجموعه داده های عمومی و بازرسی های گشت پهپاد، مجموعه های آموزشی، اعتبارسنجی و آزمایشی را برای نمونه هایی از تشخیص عایق معیوب تشکیل می دهند. در مجموع، مجموعه داده شامل 2403 تصویر است.

علاوه بر این، برای آموزش موثر مدل تشخیص هدف، داده های تصویر نیاز به برچسب گذاری دارند. برای این منظور، نرم افزار MRLabeler برای حاشیه نویسی عایق ها با دسته ها، مکان ها و عیوب شناسایی شده مربوطه استفاده می شود. هر دو عایق معمولی و معیوب با دسته کلی "عایق" برچسب گذاری شده اند که کل رشته عایق ها را در بر می گیرد. برای عایق های معیوب، محل و دسته بندی خاص نقص شناسایی شده به این صورت برچسب گذاری می شود که تحت دسته «عیب» تعیین شده است. این روش برچسب گذاری به مدل اجازه می دهد تا رابطه فضایی بین عایق ها و عیوب آنها را بیاموزد. قالب برچسب گذاری از قالب پاسکال VOC که معمولاً در زمینه CV استفاده می شود، استفاده می کند.

5-3 تشخیص عیب برای عایق های خطوط انتقال برق

بر اساس بهبود یافته YOLOV4 تصاویر بازرسی تجهیزات انتقال هوایی دارای مشکلاتی مانند اهداف نقص بسیار کوچک عایق، برخی از عایق های کمتر مهم در محیط واقعی هستند.


همپوشانی و انسداد شدید عایق و سرعت تشخیص بسیار پایین. در اینجا، یک الگوریتم بهبود یافته 4YOLOV برای تشخیص سریع و دقیق عیوب عایق پیشنهاد شده است. شکل 3 روند تشخیص را نشان می دهد [26].



شکل 3. فرآیند کلی تشخیص عیب عایق برای خطوط انتقال برق.

6-DSC3

DSC محتوای کلیدی شبکه های موبایل است و اصل آن تقسیم پیچیدگی استاندارد 3×3 به DW و PW 1×1 است. ماهیت DW استفاده از یک هسته کانولوشن برای هر کانولوشن کانال ورودی برای دستیابی به استخراج اطلاعات ویژگی است. 1×1 PW برای همجوشی خطی MAP های ویژگی چندگانه خروجی از DW استفاده شده است [27، 28]. DSC کانال خروجی را از هسته کانولوشن جدا می کند و پیچیدگی محاسباتی مدل را کاهش می دهد. شکل 4 اصل خود را در مقایسه با SC نشان می دهد.



شکل 4. نمودار شماتیک DSC.

با فرض اینکه اندازه تصویر ورودی $D_F \times D_F \times M$ باشد، محاسبه برای تصویر در رابطه (7) نشان داده شده است:

$$C = D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F \quad (7)$$

D_K به اندازه هسته کانولوشن اشاره دارد M و N به ترتیب کمیت کانال را برای ویژگی های ورودی و خروجی نشان می دهند. در صورت استفاده از DSC، محاسبه DW و PW به شرح زیر است:

$$\begin{cases} C_{DW} = D_K \cdot D_K \cdot M \cdot D_F \cdot D_F \\ C_{PW} = M \cdot N \cdot D_F \cdot D_F \end{cases} \quad (8)$$

C_{PW} و C_{DW} به ترتیب مقادیر محاسبه شده مربوط به DW و PW هستند. طبق رابطه (8)، پیچیدگی محاسباتی DSC $2/D_1/N+1$ از مقدار محاسبه SC است. در مدل کلی، $D_K \gg D_K$ در Mobile K Nets، هسته کانولوشن معمول $D_K \times D_K$ 3×3 است. بنابراین، بار محاسباتی DSC تقریباً به $1/9 - 1/8$ بار محاسباتی SC کاهش می یابد و بیان تصویر به صورت معادله (9) اصلاح می شود:

$$\frac{D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (9)$$

با توجه به الزامات بالا برای پارامترهای مدل و سرعت تشخیص هنگام استقرار در دستگاه های تلفن همراه، Mobile Net یک ابرپارامتر به نام ضریب عرض را معرفی می کند که به عنوان a نشان داده می شود. این ضریب عرض برای تنظیم کمیت کانال مدل عمل می کند و در نتیجه بر پیچیدگی محاسباتی و تعداد پارامترهای آن تأثیر می گذارد. اگرچه هیچ روش قطعی برای تعیین مقدار a وجود ندارد، اما عملکرد آن تنظیم پیچیدگی مدل با مقیاس بندی تعداد اصلی کانال ها توسط a است. با این حال، الگوریتم های جستجوی فراپارامتر یا تکنیک های خودکار ML می توانند مناسب ترین مقدار را برای نیازهای خاص در حین تعادل پیدا کنند.

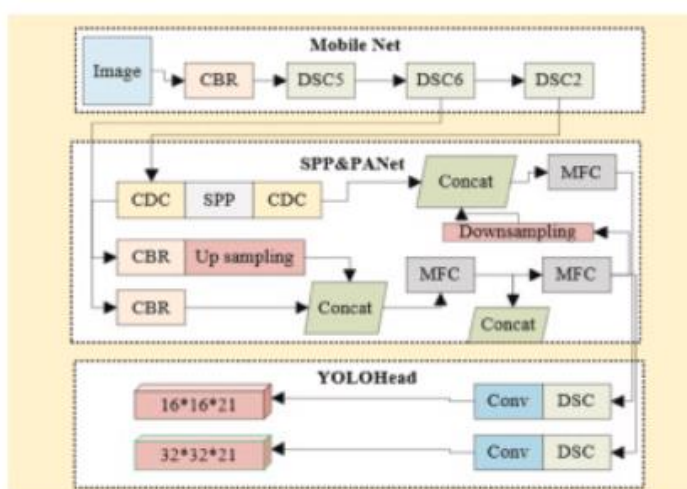
تکنیک‌ها می‌توانند مناسب‌ترین مقدار را برای نیازهای خاص پیدا کنند و در عین حال عملکرد و کارایی محاسباتی را متعادل کنند. پس از تغییر تعداد کانال‌ها در مدل، محاسبه برای محاسبه مدل در رابطه (10) نشان داده شده است:

$$C = D_K \bullet D_K \bullet \alpha M \bullet D_F \bullet D_F + \alpha M \bullet \alpha N \bullet D_F \bullet D_F \quad (10)$$

مقدار پیش فرض α برای Mobile Net استاندارد 1.0 است. کاهش می‌تواند به طور موثری مقدار محاسبه و پارامتر مدل را کاهش دهد. مقدار معمولاً 0.25، 0.5، 0.75، 1.0 یا 0.25 است.

مدل تشخیص YOLOv4 بهبود یافته است.

شکل 5 ساختار مدل YOLOv4 بهبود یافته را بر اساس Mobile Net V1 نشان می‌دهد.



شکل 5. ساختار مدل بهبود یافته YOLOv4

در شکل 5، حاشیه نویسی عددی زیر DSC، مقدار مازول های DSC استفاده شده را نشان می‌دهد. مازول Convolution (CBR) Batchnormalization Relu (CBR) درست مانند مازول Conv Batchnorm Mish (CBM) در مدل YOLOv4 است، البته Mish را در لایه تابع فعال سازی با ReLU جایگزین می‌کند. مازول کانولوشن تفاوت مرکزی (CDC) نشان می‌دهد که ورودی تحت سه محاسبه کانولوشن قرار می‌گیرد که شامل 2 نوع پیچیدگی است CBR و DSC. Model of Five Convolution (MFC) نشان می‌دهد که ورودی تحت پنج محاسبه کانولوشن قرار گرفته است که دو نوع پیچیدگی را ادغام می‌کند CBR و DSC. در مقایسه با YOLOv4، مدل بهبود یافته YOLOv4 جایگزین شبکه استخراج ویژگی ستون فقرات با Mobile Net شده است DSC. را به شبکه فیوژن ویژگی معرفی می‌کند تا DSC-Spatial Pyramid Pooling (SPP) و DSC-Path Aggregation Network (PANet) را تشکیل دهد.

7-3 شبکه استخراج ویژگی

Mobile Net به عنوان یک استخراج کننده ویژگی جدید عمل می‌کند و جایگزین شبکه استخراج ویژگی ستون فقرات 53Cross Stage Partial Darknet (53CSPDarknet) در YOLOv4 می‌شود. علاوه بر این، 224×224 مورد نیاز برای اندازه ورودی اولیه شبکه به 416×416 نرمال می‌شود [29]. با توجه به ساختار و اصل شبکه، ویژگی‌های بعد از 5، 6

و 2 ماژول کانولوشن DSC به ترتیب به عنوان ویژگی های 1، 2 و 3 استخراج می شوند. در مقایسه با سه مقیاس mao ویژگی 52 × 52، 26 × 26 و 13 × 13 در 4YOLOv، سه اندازه ویژگی mAP مدل بهبودیافته 4YOLOv به 64 × 64، 32 × 32 و 16 × 16 تبدیل می شوند. 1، 2 و 3 برای بهبود فیوژن به SPP و PANet وارد می شوند. علاوه بر این، تابع فعال سازی با تابع فعال سازی 6ReLU که برای شبکه تلفن همراه پیکربندی شده است جایگزین می شود و بیان مشخصه آن در رابطه (11) نشان داده شده است:

$$y = \min [6, \max (x, 0)] \quad (11)$$

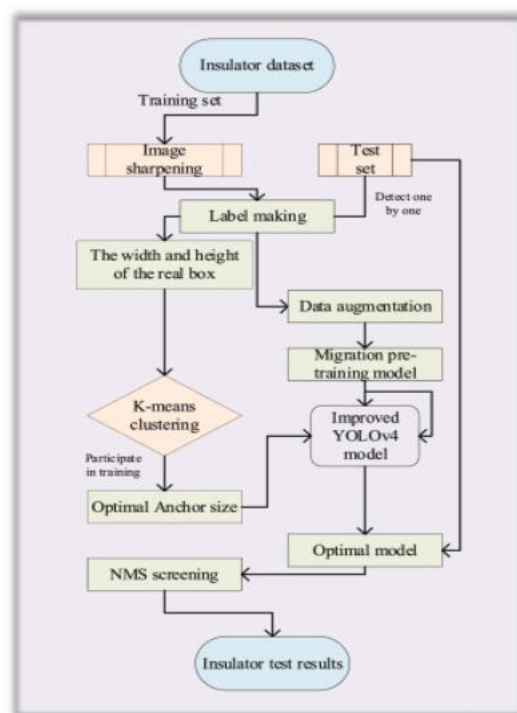
DSC-PANet و DSC-SPP

نتایج آزمایش نشان می دهد که مقدار کل پارامتر 4 YOLOv تقریباً 64.43 میلیون است. اگر فقط شبکه استاندارد موبایل با $\alpha = 1$ برای جایگزینی شبکه استخراج ویژگی CSPDarknet 53 استفاده شود، تعداد پارامترهای مدل حدود 41 میلیون است. کمیت پارامتر تا حد زیادی کاهش نیافته است [30]. این به این دلیل است که بیشتر پارامترهای 4 YOLOv در SC SPP و PANet قرار دارند DSC به SPP و PANet آورده می شود تا مدل سبک وزن بیشتری داشته باشد و در DSC-SPP و DSC-PANet بهینه شده است. جزئیات خاص به شرح زیر است. اولین مرحله جایگزینی ماژول SC متشکل از 3 CBR قبل و بعد از شبکه SPP با یک ماژول CDC است. این بدان معناست که دومین CBR در $3 \times \text{Conv}$ با DSC جایگزین می شود، در حالی که تعداد کانال های خروجی بدون تغییر باقی می ماند. مرحله دوم بهبود پنج ماژول (SC تبدیل $5 \times$) در ماژول های PANet به MFC است و CBR های دوم و چهارم با DSC جایگزین می شوند. مرحله سوم جایگزینی SC با یک هسته 3×3 در YOLOHead [با DSC 31] است. با اجرای این اصلاحات، تعداد کل پارامترهای مدل بهبود یافته تشخیص 4 YOLOv به 12.75 میلیون می رسد که به طور قابل توجهی ردپای آن را در مقایسه با مدل اصلی 4 YOLOv کاهش می دهد [32]

8-3 طراحی تجربی

فرآیند آزمایشی و تنظیمات پارامتر

این مدل همانطور که در شکل 6 مشخص شده است تحت آموزش و آزمایش قرار می گیرد. علاوه بر این، ImageNet، یک مجموعه داده عمومی بزرگ، برای پیش آموزش مدل استفاده می شود. از طریق روش یادگیری انتقال مرحله ای به مجموعه داده تصویر عایق خط انتقال برق منتقل می شود. قبل از آموزش مدل، تبدیل های هندسی و نوری، شامل چرخاندن، مقیاس گذاری و رنگ به طور تصادفی برای گسترش نمونه اتخاذ می شوند. علاوه بر این، تکنیک های آموزشی مانند صاف کردن برچسب، افزایش داده های موزاییک، و تضعیف آنیل کسینوس برای تقویت استحکام و توانایی تعمیم مدل یکپارچه شده اند.



شکل 6. فرآیند آموزش و تست مدل.

اندازه‌های قاب اولیه مشخص شده در شکل 6 از طریق خوشه‌بندی در مجموعه آموزشی با استفاده از الگوریتم خوشه‌بندی K-means به دست می‌آیند. اندازه‌های آن به صورت $[15, 14, 21, 135, 21, 15, 39, 18, 81, 21, 36, 107, 252, 52]$ ، نشان دهنده نه مجموعه فریم قبلی با ابعاد مختلف است. فریم‌های قبلی در سه گروه اندازه اول، میانی و آخر به ترتیب با ویژگی‌های mAP با وضوح 16×16 ، 32×32 و 64×64 مطابقت دارند. آنها برای شناسایی اهداف با اندازه‌های مختلف استفاده می‌شوند. جدول 1 تنظیمات پارامتر را در طول آموزش و آزمایش مدل بهبود یافته 4YOLOv نشان می‌دهد.

جدول 1. پیکربندی پارامتر مدل 4YOLOv بهبود یافته.

مرحله 2	مرحله 1	نام پارامتر
2	8	اندازه دسته
1×10^{-4}	1×10^{-3}	میزان یادگیری اولیه
50	50	زمان‌های آموزش
9:1	0.3	آستانه سرکوب غیر حداکثری (NMS)
	0.01	نسبت نمونه
	1×10^{-6}	ارزش صاف کردن برچسب

حداقل نرخ یادگیری بازپخت کسینوس		
---------------------------------	--	--

4- نتایج تجربی و تجزیه و تحلیل

1-4 تأثیر شاخص‌های مختلف بر اثربخشی مدل‌های تشخیص

تأثیر نسبت‌های مختلف نمونه

برای ارزیابی تأثیر اندازه نمونه بر دقت تشخیص مدل بهبودیافته 4YOLOv، نسبت نمونه‌های تصویر در مجموعه آموزشی (شامل مجموعه اعتبارسنجی) به نمونه‌های موجود در مجموعه آزمایشی به طور سیستماتیک روی 5:5، 6:4 تنظیم می‌شود. به ترتیب 7:3، 8:2 و 9:1. علاوه بر این، 10 درصد از نمونه‌های تصویر در مجموعه آموزشی به عنوان یک مجموعه تأیید گرفته می‌شود. جدول 2 توزیع نمونه خاص را نشان می‌دهد. جدول 3 نتایج آزمایش را تحت نسبت‌های مختلف نمونه، شامل R-value، P-value، میانگین دقت (AP) و شاخص‌های عملکرد mAP نشان می‌دهد.

جدول 2. توزیع نسبت‌های نمونه متنوع.

نسبت تعداد نمونه‌های تصویر		5:5	6:4	7:3	8:2	9:1
نام مجموعه‌های داده	مجموعه آموزشی	1081	1297	1514	1730	1946
	مجموعه تأیید	120	144	168	192	216
	مجموعه تست	1202	962	721	481	241

جدول 3. نتایج آزمون برای نسبت‌های مختلف نمونه.

نام‌های شاخص	AP- عیق (%)	p- عیق (%)	R- عیق (%)	نقشه (%)	AP- کاستی (%)	P- کاستی (%)	R- کاستی (%)
نسبت از تعداد نمونه های تصویر	5:5 90.2	95.1	81	86	82.5	91	77.8
	6:4 92.5	95	85	90	87.5	91.5	84
	7:3 92.6	95.4	84	89	87	94	85.5
	8:2 90.3	94	83	88.5	88	91	85
	9:1 94.5	95	91	93.8	92	97.5	93

جدول ۲، جدول ۳ روند صعودی را در مقادیر P ، R ، AP و mAP نشان می دهد که نسبت مجموعه های آموزشی به مجموعه های آزمایشی افزایش می یابد. در میان آنها، $AP-Insulator$ ، $P-Insulator$ ، و mAP معیارهای کلیدی هستند که برای ارزیابی عملکرد مدل های تشخیص اشیا، به ویژه در هنگام برخورد با مقوله های خاص مانند عایق ها، بسیار مهم هستند. $AP-Insulator$ مدل را در تشخیص عایق ها اندازه گیری می کند، که منعکس کننده ثبات و دقت مدل در شناسایی عایق ها است. $P-Insulator$ بیشتر بر نسبت عایق های واقعی شناسایی شده توسط مدل تمرکز می کند و دقت آن را نشان می دهد. در همین حال، mc یک شاخص عملکرد جامع برای وظایف تشخیص اشیا چند کلاسه است که عملکرد کلی مدل را با محاسبه میانگین تمام AP های کلاس ارزیابی می کند. یک mAP بالاتر نشان دهنده قابلیت تشخیص متعادل تر و برجسته تر در دسته های مختلف است. این معیارها در کاربردهایی مانند سیستم های قدرت از اهمیت قابل توجهی برخوردار هستند، نه تنها به درک عملکرد مدل در تشخیص تجهیزات حیاتی مانند عایق ها کمک می کنند، بلکه بینش های ضروری را برای بهینه سازی و بهبود مدل ارائه می دهند. با افزایش مداوم این معیارها، دقت و قابلیت اطمینان مدل های تشخیص اشیا را می توان بهبود بخشید، بنابراین از عملکرد ایمن و پایدار سیستم های قدرت محافظت بهتری می کند. علاوه بر این، تأثیر بر اهداف نقص بیشتر است و روند صعودی چشمگیرتر است. هنگامی که نسبت نمونه روی ۹:۱ تنظیم می شود، تعداد نمونه های آموزشی و اعتبارسنجی کافی است و تقریباً تمام شاخص های عملکرد در نتایج آزمایش مدل می توانند به حداکثر مقدار برسند، با هر شاخص بیش از ۹۰٪ و مقدار mAP به ۹۳.۸ می رسد.٪. این مدل در این زمان به بالاترین دقت تشخیص دست می یابد. از این رو، نسبت تخصیص نمونه ۹:۱ در تحلیل های بعدی ضریب های عرض مختلف α ، تشخیص و الگوریتم های تیز کردن استفاده می شود.

۲-۴ نتایج آزمایش برای ضریب های مختلف عرض α

آزمایش های شبیه سازی برای مقادیر رایج α ، مانند ۰.۲۵، ۰.۵۰، ۰.۷۵، و ۱.۰ انجام می شوند و نتایج آن ها برای تجزیه و تحلیل تأثیر α بر دقت تشخیص مقایسه و تجزیه و تحلیل می شوند. جدول ۴ نشانگرهای P -value، R -value، AP و mAP نتایج آزمایش را تحت مقادیر مختلف α فهرست می کند.

جدول ۴. نتایج آزمایش ضریب های مختلف عرض الف

نام های شاخص	AP- عایق (%)	p- عایق (%)	R- عایق (%)	نقشه (%)	AP- کاستی (%)	P- کاستی (%)	R- کاستی (%)
عرض چند برابری	0.25 85	97	72.5	71	60	75	48
	0.5 91	95	85	87	84	79	84
	0.75 95	96	90	90	91	93	91

92	95	92	91	89	95	94	1	
----	----	----	----	----	----	----	---	--

جدول 4 نشان می دهد که با افزایش مقدار α ، مقادیر P ، R و AP مقررهای معیوب روند صعودی را نشان می دهند. مقادیر R و AP عایق های معمولی روند صعودی را نشان می دهند، در حالی که مقدار P به طور ملایم کاهش می یابد، اما هر دو بیش از 94٪ هستند. علاوه بر این، mAP کلی عایق های معمولی روند صعودی مشابهی را نشان می دهد. سایر شاخص های عملکرد زمانی که $a=1.0$ به اوج خود می رسند، به جز مقدار P کلاس عایق معمولی. با توجه به استقرار برنامه واقعی، مقدار α را می توان به طور انعطاف پذیر برای دستیابی به سبک وزن، دقت بالا و عملکرد بالا در زمان واقعی مدل تنظیم کرد.

3-4 تاثیر الگوریتم های مختلف تیز کردن

برای کاهش چالش های مربوط به خطوط نامشخص و کنتراست کم ناشی از شباهت بین عایق ها و محیط پس زمینه، از روش تیز کردن لاپلاسیس برای افزایش هدف عایق استفاده می شود. علاوه بر این، مقایسه ای بین این روش و سه روش تیز کردن دیگر، یعنی عملگرهای Sobel، Prewitt و Laplace انجام شده است. جدول 5 نتیجه تشخیص مدل را پس از پردازش تصویر با استفاده از روش های مختلف شارپنینگ نشان می دهد.

جدول 5. نتایج آزمایش روش های مختلف تیز کردن.

نام های شاخص	AP-	P-	R-	نقشه (%)	AP- کاستی (%)	P- کاستی (%)	R- کاستی (%)
تیز کردن	94.5	96	91.6	93.8	93.1	97	94.1
روشن							
Prewitt	94	93.9	89.3	93.8	93.6	93.9	93.8
سویل	94.7	93.4	91.4	95.2	95.6	98.4	95.2
روشن به معنای	94.3	95.2	89.7	94	93.6	96.9	93.9
لاپلاس	96.1	96.7	93.9	97.3	98.4	96	97.3

جدول 5 تاکید می کند که ارزش AP کلاس نقص عایق هنگام استفاده از روش واضح سازی تصویر در مقایسه با پردازش غیرشارپنینگ بالاتر است. این را می توان به عنوان بهبود توانایی تشخیص مدل برای نقص عایق پس از معرفی پردازش وضوح

تصویر درک کرد. در میان چهار الگوریتم تیز کردن در نظر گرفته شده، تیز کردن لاپلاسی به عنوان عملکرد بهینه در تمام شاخص‌های عایق ظاهر می‌شود و بالاترین مقادیر AP و R را برای نقص عایق دارد. علاوه بر این، mAP کلی به دست آمده با این روش می‌تواند به 97.3 درصد برسد که ظرفیت آن را برای دستیابی به بالاترین دقت تشخیص برجسته می‌کند.

5-4 مقایسه اثرات مدل‌های مختلف تشخیص

علاوه بر مدل بهبودیافته 4YOLOv، چهار مدل شبکه عصبی کانولوشنال مبتنی بر منطقه سریع (RCNN)، SSD، 3YOLOv و 4YOLOv برای مقایسه پیاده‌سازی شده‌اند. جدول 6 نتایج تشخیص الگوریتم‌های مختلف را تحت مجموعه‌های آموزشی و آزمایشی یکسان ارائه می‌دهد. مقدار α Mobile Net در مدل بهبودیافته 4YOLOv 1.0 است.

جدول 6. مقایسه نتایج تشخیص الگوریتم‌های مختلف.

نام های شاخص		AP-	امتیاز F1-	نقشه AP-		امتیاز F1-	FPS
		عابق	عابق	کاستی	کاستی		
		(%)	(*10-2)	(%)	(%)	(*10-2)	
تشخیص	سرعت RCNN	87.3	79	80	92.5	92	1
مدل	SSD	93.8	81	84.4	75	72	28
	YOLOv1	81	75	81.2	82.3	83	17
	YOLOv2	84.2	83	85	84	85	20
	YOLOV3	89	88	88.2	87	89	24
	YOLOV4	96	96	96.2	96.4	95	19
	EfficientDet	91.2	90.5	89.7	88.6	87.8	35
	ریتا نت	88.7	87.2	86.4	90.2	89.5	30
	CenterNet	93.4	92.7	91.8	85.6	84.2	40
	آبشار R-	94.8	94.2	93.6	88.9	87.5	15
	CNN						
	HRNet	90.1	89.4	88.7	91.5	90.9	25
	بهبود یافته	94.5	95.9	93.8	93.1	94	53
	YOLOV4						

جدول 6 نشان می دهد که در بین تمام مدل های تشخیص عیب، 4YOLOv، EfficientDet، 4YOLOv بهبود یافته و CenterNet عملکرد برتر را از نظر قابلیت تشخیص عایق نشان می دهند. قابل ذکر است، این مدل ها امتیازهای ستودنی AP-insulator (%) را نشان می دهند که به ترتیب به 96.0، 91.2، 94.5 و 93.4 می رسند. به طور مشابه، امتیازات عایق امتیاز 1F آنها منعکس کننده سطوح بالایی از عملکرد است، با نمرات 96.0، 90.5، 95.9 و 92.7. شایان ذکر است که 4YOLOv بهبود یافته عملکرد بسیار خوبی در تمام جنبه ها به دست آورده است. امتیازات AP آن در دسته های عایق و نقص (به ترتیب 94.5 و 93.1) برتری آن را در عملکرد کلی نشان می دهد. علاوه بر این، مقدار بالای 53FPS آن، عملکرد کارآمد آن را در سناریوهای بلادرنگ بیشتر نشان می دهد. ماتریس مقایسه بین مدل بهبود یافته و مدل نقص در جدول 7 فهرست شده است.

جدول 7. ماتریس مقایسه بین مدل بهبود یافته و مدل نقص.

واقعی/پیش بینی	بهبود یافته	کاستی
بهبود یافته	TP=480	FN=20
کاستی	FP=15	TN=385

در جدول 7، مدل بهبودیافته دقت و یادآوری بالاتری را در وظایف تشخیص عیب نشان می دهد. 480 نقص وجود دارد که به طور دقیق به عنوان نقص شناسایی شده است. (True Positive) با این حال، 20 نقص به اشتباه به عنوان نرمال (منفی کاذب) طبقه بندی می شوند که نشان دهنده سطح معینی از حذف است. علاوه بر این، 15 نرمال به اشتباه به عنوان نقص پیش بینی شده اند (مثبت کاذب)، و 385 نرمال به درستی به عنوان نرمال (منفی واقعی) طبقه بندی می شوند. این مدل دقت بالایی را در تشخیص عیب نشان می دهد، اما برای میزان حذف به بهبود بیشتری نیاز است. به طور کلی، مدل بهبودیافته ممکن است در عمل به نتایج خوبی دست یابد، اما اصلاح مداوم همچنان برای افزایش سطوح عملکرد کلی ضروری است. به طور کلی، مدل های مختلف مزایای خود را در وظایف و دسته بندی های مختلف نشان می دهند. عملکرد جامع و سرعت پردازش بلادرنگ مدل 4YOLOv بهبودیافته آن را به اولین انتخاب شایسته توجه تبدیل کرده است، در حالی که عملکرد سایر مدل ها در دسته ها و شاخص های متنوع باید به طور جامع سنجیده و بر اساس نیازهای واقعی انتخاب شود.

5- بحث

این کار سهم برجسته ای در زمینه CV، به ویژه در کاربرد الگوریتم های تشخیص اشیا داشته است. با پرداختن به موضوع تشخیص عیب مقرر در خطوط انتقال برق، مجموعه ای از روش ها و استراتژی های ابتکاری پیشنهاد شده است که به تشخیص کارآمد و دقیق عیوب مقرر دست می یابد. در مرحله اول، این کار به ساخت، تقویت، و پیش پردازش مجموعه داده های تصویر عیب عایق می پردازد. برای پرداختن به مسائل احتمالی عدم تعادل نمونه در کاربردهای عملی، این کار یک روش تقویت داده ها را بر اساس تقسیم بندی GraphCut پیشنهاد می کند که به طور موثر کمیت و تنوع تصاویر عایق معیوب را گسترش می دهد. این نه تنها پشتیبانی از داده های غنی را برای آموزش مدل بعدی فراهم می کند، بلکه توانایی تعمیم مدل را نیز

افزایش می دهد. ثانیاً، این کار بر بهبودهای سبک وزن در الگوریتم 4YOLOv برای کاهش پیچیدگی مدل، کاهش مصرف حافظه و بهبود سرعت تشخیص تمرکز دارد. با استفاده از MobileNet به عنوان شبکه استخراج ویژگی و ترکیب ساختارهای DSC-SPP و DSC-PANet، یک مدل تشخیص عیب عایق بسیار کارآمد و سبک با موفقیت ساخته شده است. با حفظ دقت تشخیص بالا، این مدل به طور قابل توجهی سرعت تشخیص را افزایش می دهد و نیازهای دستگاه های تشخیص لبه را در زمان واقعی برآورده می کند. علاوه بر این، این کار از فناوری پیش پردازش شارپ لاپلاسی برای بهبود جزئیات تصویر و لبه استفاده می کند.

وضوح، عملکرد تشخیص مدل را بیشتر بهبود می بخشد. از طریق این روش، کاستی های بالقوه در دقت تشخیص مدل سبک وزن 4YOLOv با موفقیت برطرف می شود و به سطح دقت تشخیص کلی 97.3٪ دست می یابد. به طور خلاصه، این کار کمک قابل توجهی به تشخیص عیب عایق در خطوط انتقال برق داشته است. با بهینه سازی مجموعه داده ها، بهبود ساختارهای الگوریتم، و معرفی تکنیک های پیش پردازش جدید، یک مدل تشخیص عیب عایق کارآمد و دقیق با موفقیت اجرا می شود. این کار می تواند پشتیبانی قوی برای بازرسی های ایمنی در صنعت برق ارائه دهد و بینش های ارزشمندی را برای کاربرد فناوری CV در سایر زمینه ها ارائه دهد. در مقایسه با مطالعه Gai و همکاران. (2023) [33]، این کار دقت و سرعت مدل شناسایی نقص خط انتقال برق را با معرفی فناوری CV افزایش می دهد. استفاده از تکنیک های پیشرفته مانند DSC مدل را بهینه می کند و عملکرد عالی را در آزمایش ها نشان می دهد. با ساخت یک مجموعه داده تصویر عایق جامع و بحث در مورد تأثیر پارامترهای مختلف بر اثربخشی مدل، پیکربندی پارامتر بهینه مدل آشکار می شود. در مقایسه با سایر الگوریتم ها، مدل مزیت های منحصر به فردی را در کارایی و دقت تشخیص به نمایش می گذارد و راه حلی خلاقانه و عملی برای تشخیص نقص خط انتقال برق ارائه می کند.

6- نتیجه گیری

هدف این کار افزایش دقت، سرعت، و قابلیت تعمیم مدل های تشخیص شی برای کمک به بازرسان شبکه در تشخیص وضعیت خطوط انتقال برق است. در مرحله اول، یک الگوریتم تقسیم بندی مبتنی بر GraphCut برای گسترش نمونه تصاویر عایق معیوب استفاده می شود، و الگوریتم لاپلاسی برای واضح تر کردن مجموعه تصویر استفاده می شود، در نتیجه یک مجموعه داده تصویر عایق جامع از خطوط انتقال برق ساخته می شود. ثانیاً، با توجه به 1MobileNet V، DSC-SPP، و DSC-PANet، بهبودهایی در مدل تشخیص عیب عایق بر اساس 4YOLOv به دست آمده است. علاوه بر این، اثرات نسبت های مختلف نمونه، ضریب عرض α ، و روش های تیز کردن بر نتایج تشخیص مدل مورد بحث قرار می گیرد. نتایج تشخیص مدل بهبود یافته 4YOLOv با سایر الگوریتم های تشخیص شی (مانند RCNN سریعتر، SSD، 3YOLOv و 4YOLOv) مقایسه می شود. نتایج نشان می دهد که وقتی نسبت نمونه روی 9:1 تنظیم می شود، مقدار نمونه آموزشی و اعتبارسنجی کافی وجود دارد. تقریباً همه شاخص های عملکرد در نتایج تشخیص مدل می توانند به حداکثر مقادیر خود برسند، با هر شاخص بیش از 90٪ و مقدار mAP به 93.8٪. این نشان می دهد که مدل در این تنظیم به بالاترین دقت تشخیص دست می یابد. در $1.0\alpha =$ ، تمام شاخص های عملکرد دیگر به حداکثر مقادیر خود می رسند، به جز مقدار P در رده عایق معمولی. در مقایسه با پردازش بدون شارپینگ، استفاده از روش های شفاف سازی تصویر منجر به مقادیر بالاتر AP برای دسته نقص عایق می شود. این بدان معناست که توانایی مدل برای تشخیص عیوب عایق پس از معرفی پردازش وضوح تصویر بهبود می یابد. سرعت تشخیص تصویر 4YOLOv بهبود یافته تقریباً 2.8 برابر سریعتر از 4YOLOv است که نشان می دهد این مدل می تواند عیوب عایق را در خطوط انتقال برق با دقت و سرعت بالا تشخیص دهد. محدودیت این کار در این واقعیت نهفته است که در دسترس بودن و

دقت مدل تشخیص شی به شدت به داده‌های تصویر آموزشی بستگی دارد، در حالی که تعداد کمی از تصاویر بازرسی هوایی واقعی از گشت‌های خط شبکه وجود دارد. به ویژه خطوط انتقال برق حاوی عایق‌های متعدد با عیوب متعدد و اجسام خارجی مختلف است. در تصاویر گشت واقعی، عدم تعادل شدید بین نمونه‌های معمولی و معیوب وجود دارد. بنابراین، بهینه‌سازی بیشتر کمیت نمونه برای شناسایی و تشخیص موثر عیوب در خطوط انتقال برق ضروری است. این کار کمک قابل توجهی به تشخیص عیوب عایق در خطوط انتقال برق داشته است. از طریق بهینه‌سازی مجموعه‌های داده، بهبود در ساختار الگوریتم 4YOLOv و معرفی تکنیک‌های پیش پردازش تیز کردن لاپلاسی، یک مدل تشخیص کارآمد و دقیق با موفقیت توسعه یافته است. این دستاورد امکان تشخیص به موقع و دقیق عیوب عایق را فراهم می‌کند و پشتیبانی قوی برای بازرسی‌های ایمنی در صنعت برق ارائه می‌دهد.

با این حال، محدودیت‌های مدل تشخیص شی در تصاویر بازرسی هوایی واقعی، کاوش بیشتر را ضروری می‌کند. در مرحله اول، داده‌های تصویر آموزشی اضافه می‌شود، مجموعه آموزشی با فناوری افزایش داده‌ها گسترش می‌یابد، و نمونه‌های نقص و اجسام خارجی عایق به طور مصنوعی برای افزایش سازگاری مدل سنتز می‌شوند. در مرحله دوم، روش‌های انطباق مجموعه داده‌های متقابل برای بهبود دقت و استحکام مدل در داده‌های نامتعادل با استفاده از داده‌های سایر زمینه‌ها یا منابع معرفی شده‌اند. علاوه بر این، قابلیت تعمیم مدل با استفاده از یادگیری انتقال و یادگیری چند وظیفه‌ای برای رسیدگی به انواع مختلف و نقص‌های پیچیده در خطوط انتقال برق افزایش می‌یابد. در نهایت، با ادغام سایر منابع اطلاعاتی، مانند داده‌های حسگر و داده‌های سری زمانی، عملکرد مدل تشخیص شی را می‌توان با استفاده جامع از اطلاعات چند منبع بهبود بخشید. به طور همزمان، برای افزایش عملکرد طبقه‌بندی مدل، پیش‌پردازش داده‌ها و مهندسی ویژگی‌ها را می‌توان بهینه کرد، مدل‌ها و فرآیندهای مناسب را انتخاب کرد و مجموعه داده‌های نامتعادل را می‌توان پردازش کرد. علاوه بر این، یادگیری مجموعه و استراتژی‌های ترکیب مدل را می‌توان اعمال کرد، از منظم‌سازی می‌توان برای جلوگیری از برازش بیش از حد استفاده کرد و بهینه‌سازی پس از پردازش را می‌توان انجام داد. کاربرد جامع این معیارها می‌تواند به طور موثر عملکرد طبقه‌بندی را بهبود بخشد.

منابع

- [1] X. Li, Z. Li, H. Wang, W. Li
Unmanned aerial vehicle for transmission line inspection: status, standardization, and perspectives
Front. Energy Res., 9 (1) (2021), Article 713634
- [2] F. Nekovar, J. Faigl, M. Saska
Multi-tour set traveling salesman problem in planning power transmission line inspection
IEEE Rob. Autom. Lett., 6 (4) (2021), pp. 6196-6203
- [3] Y. Zhang, C. Lv, D. Wang, W. Mao, J. Li
A novel image detection method for internal cracks in corn seeds in an industrial inspection line
Comput. Electron. Agric., 197 (7) (2022), Article 106930
- [4] M. Witek
Structural integrity of steel pipeline with clusters of corrosion defects Materials, 14 (852) (2021), pp. 1-15
- [5] X. Hu, H. Liu, C. Qiu, D. Liu
Inspection of line defects in transition metal dichalcogenides using a microscopic hyperspectral imaging technique J. Phys. Chem. Lett., 2022 (9) (2022), p. 13
- [6] F. Zhou, G. Wang, Y. Zheng
SA RCNN for occluded damper detection in the inspection of power transmission line
J. Phys. Conf., 1871 (1) (2021), Article 012081
- [7] Y. Ma, Q. Li, L. Chu, Y. Zhou, C. Xu
Real-time detection and spatial localization of insulators for UAV inspection based on binocular stereo vision Rem. Sens., 13 (2) (2021), p. 230
- [8] S.F. Stefenon, M.P. Corso, A. Nied, F.L. Perez
Classification of insulators using neural network based on computer vision IET Gener. Transm. Distrib., 2022 (6) (2022), p. 16
- [9] Z. Wan, Q.D. Wang, D. Liu, J. Liang
Effectively improving the accuracy of PBE functional in calculating the solid band gap via machine learning Comput. Mater. Sci., 198 (18) (2021), Article 110699
- [10] LauraFarrelly Pillozzi, A. Francis Marcucci, Claudio GiuliaConti
Topological nanophotonics and artificial neural networks Nanotechnology, 32 (14) (2021), pp. 4-5
- [11] C. Liu, Y. Wu, J. Liu, J. Han
MTI-YOLO: a light-weight and real-time deep neural network for insulator detection in complex aerial images Energies, 14 (5) (2021), p. 1426
- [12] G. Envelope, H.A. Min, Z.B. Feng, Z.A. Min
Insulator detection and damage identification based on improved lightweight YOLOv4 network - ScienceDirect Energy Rep., 7 (5) (2021), pp. 187-197
- [13] H. Mei, H. Jiang, F. Yin
Terahertz imaging method for composite insulator defects based on edge detection algorithm
IEEE Trans. Instrum. Meas., 2021 (70) (2021), p. 70
- [14] E.H. Khalil, K. Adam, M. Kelly
Towards the in-situ detection of spin charge accumulation at a metal/insulator interface using STEM-EELS technique Microsc. Microanal., 2022 (1) (2022), p. 1
- [15] Z. Qiu, X. Zhu, C. Liao, D. Shi, W. Qu
Detection of transmission line insulator defects based on an improved lightweight YOLOv4 model
Appl. Sci., 12 (3) (2022), p. 1207
- [16] Y. Jiang, S. Li, P. Zhu
Electrochemical DNA biosensors based on the intrinsic topological insulator BiSbTeSe 2 for potential application in HIV determination ACS Appl. Bio Mater., 5 (3) (2022), pp. 1084-1091
- [17] C. Liu, Y. Wu, J. Liu
Improved YOLOv3 network for insulator detection in aerial images with diverse background interference Electronics, 10 (7) (2021), p. 771

- [18] H. Peng, Z. Wang, X. Liu
Railway insulator detection based on adaptive cascaded convolutional neural network
IEEE Access, 9 (99) (2021) 1–1
- [19] F. Deng, Z. Xie, W. Mao
Research on edge intelligent recognition method oriented to transmission line insulator fault detection
Int. J. Electr. Power Energy Syst., 139 (5) (2022), Article 108054
- [20] L.A. Yi, B. Mn, Y. Envelope
Insulator defect detection for power grid based on light correction enhancement and YOLOv5 model
Energy Rep., 8 (8) (2022), pp. 807-814
- [21] B. Wang, F. Ma, L. Ge, H. Ma, H. Wang, M.A. Mohamed
Icing-EdgeNet: a pruning lightweight edge intelligent method of discriminative driving channel for ice thickness of transmission lines IEEE Trans. Instrum. Meas., 70 (2020), pp. 1-12
- [22] L. Feng, B. Wang, F. Ma, H. Ma, M.A. Mohamed
Identification of key links in electric power operation based-spatiotemporal mixing convolution neural network Comput. Syst. Sci. Eng., 46 (2) (2023)
- [23] R. Sundaram, S.K. Vasudevan
Marker and modified graph cut algorithm for augmented reality gaming Int. J. Adv. Intell. Paradigms, 2022 (2) (2022), p. 22
- [24] Z. Long, Y. Gao, H. Meng
Clustering based on local density peaks and graph cut Inf. Sci., 600 (7) (2022), pp. 263-286
- [25] S.S. Khan, M. Khan, Y. Alharbi
Hybrid sharpening transformation approach for multifocus image fusion using medical and nonmedical images J. Healthcare Eng., 2021 (15) (2021), p. 2021
- [26] K. Wang, M. Liu
Toward structural learning and enhanced YOLOv4 network for object detection in optical remote sensing images Adv. Theory Simul., 2022 (6) (2022), p. 5
- [27] Y. Huang
Transfer remaining useful life estimation of bearing using depth-wise separable convolution recurrent network Measurement, 176 (1) (2021), pp. 90-91
- [28] Z. Huang, J. Wu, F. Xie
Automatic surface defect segmentation for hot-rolled steel strip using depth-wise separable U-shape network Mater. Lett., 301 (8) (2021), Article 130271
- [29] E. Alsaadi, N. Abbadi
An automated mammals detection based on SSD-mobile Net J. Phys. Conf., 1879 (2) (2021), Article 022086
- [30] X. Li, C. Duan, Y. Zhi
Wafer crack detection based on Yolov4 target detection method J. Phys. Conf., 1802 (2) (2021), Article 022101
- [31] F. Li, Z. Jiang, S. Zhou
Spilled load detection based on lightweight YOLOv4 trained with easily accessible synthetic dataset Comput. Electr. Eng., 100 (8) (2022), Article 107944
- [32] B. Yang, J. Wang
An improved helmet detection algorithm based on YOLO V4 Int. J. Found. Comput. Sci., 33 (7) (2022), pp. 887-902
- [33] R. Gai, N. Chen, H. Yuan
A detection algorithm for cherry fruits based on the improved YOLO-v4 model Neural Comput. Appl., 35 (19) (2023), pp. 13895-13906

Defect detection of insulations of power transmission lines based on improved lightweight network model with the help of computer vision

Majid Keshavarz* - Yasouj Boys Technical and Vocational University
(Skeshavarz.tvu.ac.ir@gmail.com)

Poya Alam spring plantain - Student of Yasouj Technical and Vocational University
(Poyaalam8000@gmail.com)

Abstract

The purpose of this work is to ensure the safe operation of power transmission lines and reduce maintenance costs and problems. It examines the application of computer vision (CV) in identifying faults in power transmission lines. In addition, this work proposes a method to improve the lightweight network model to provide an effective identification model to solve the power transmission line fault problem. In the first step, GraphCut and Laplace segmentation algorithms are used to expand and refine the image of the electricity transmission line. Secondly, according to the depth separable complexity algorithm, a network based You Only Look Once 4 (YOLOv4) fault detection model for power transmission line insulation is proposed. In addition, MobileNetV1 is used to improve this lightweight network model. Finally, this work uses ImageNet, a large public dataset, to test the proposed model. The research results show that: (1) in the model test results, all the research indices of the model are more than 90%. The excellent detection of this model. (2) The improved YOLOv4 model can increase the detection speed to 53fps at the cost of 2.4% accuracy. (3) The improved YOLOv4 model can detect the insulation defects to a certain extent. The above results show that the improved YOLOv4 model can predict more efficiently and reduce unnecessary false positives. This shows that the proposed model is feasible and expected in practice for detecting power line faults. These findings fully demonstrate the critical value of this work in increasing the efficiency and accuracy of prediction, thus providing a strong preference for transmission line fault detection in practical applications.

Keywords: computer vision, lightweight network, separable complexity, segmentation diagram, power transmission line insulation