

بهبود شناسایی عیوب در تصاویر EL سلول‌های خورشیدی با رویکرد مبتنی بر تمایز بین وجهی تصویر و فیلتر فوریه بالا گذر تنظیم شده

سیدعماد موسویان^۱ و شهریار برادران شکوهی^۲

چکیده

انرژی خورشیدی به عنوان یک جایگزین تجدیدپذیر برای سوخت‌های فسیلی، اهمیت بالایی در صنعت و زندگی روزمره دارد. با این حال، نقص‌های ساختاری در سلول‌های خورشیدی، توان تولیدی آن‌ها را به شکل چشمگیری کاهش می‌دهد. از این رو، شناسایی این عیوب با استفاده از روش‌های یادگیری عمیق در سال‌های اخیر مورد توجه ویژه‌ای قرار گرفته است. یکی از روش‌های اصلی ارزیابی، استفاده از تصاویر الکترومینیسانس (EL) سلول‌ها است. این تصاویر با وجود اطلاعات غنی از عیوب، دارای نویز ذاتی بالایی هستند که می‌تواند بر عملکرد مدل‌های یادگیری عمیق تأثیر بگذارد. در این مقاله، ما مدل FDFNet، یک معماری دو وجهی مبتنی بر ResNet، را برای شناسایی عیوب در تصاویر EL ارائه کرده‌ایم. این مدل به صورت همزمان تصویر اصلی و نسخه پیش‌پالایش شده آن توسط یک فیلتر فوریه تنظیم شده را به عنوان ورودی دریافت می‌کند. این فیلتر به صورت هدفمند، ضمن حذف نویز، فرکانس‌های بالای مرتبط با عیوب را برجسته می‌سازد. همچنین، برای ادغام بهینه ویژگی‌های استخراج شده از هر وجه، ماژول ادغام توجه مبتنی بر تمایز (DAF) معرفی شده است. ارزیابی رویکرد پیشنهادی بر روی مجموعه داده ELPV نشان داد که مدل ما به دقت F1-Score وزن‌دار ۸۹٫۱۷٪ دست یافته که بیانگر بهبود قابل توجهی نسبت به روش‌های مشابه است. کد پیاده‌سازی مدل پیشنهادی به آدرس <https://github.com/EmadMousavian/FDFNet> در دسترس است.

کلید واژه‌ها

سلول‌های خورشیدی، شناسایی عیوب، فیلتر فوریه، شبکه‌های کانولوشنی، رویکرد مبتنی بر توجه.

۱- مقدمه

فتوولتائیک^۱ (PV)، در پایداری بلندمدت انرژی خورشیدی امری حیاتی است. فناوری ساخت سلول‌های PV به دو نوع متداول مونوکریستال^۲ و پلی‌کریستال^۳ تقسیم می‌شود. سلول‌های مونوکریستال از یک شمش سیلیکون با ساختار کریستالی واحد تولید شده و به دلیل ساختار یکپارچه، بازدهی بالاتر و ظاهری یکنواخت دارند، اما فرآیند تولید آن‌ها پیچیده‌تر و پرهزینه‌تر است. در مقابل، سلول‌های پلی‌کریستال از ذوب و انجماد قطعات متعدد سیلیکون ساخته می‌شوند که منجر به تشکیل ساختاری با کریستال‌های نامنظم می‌شود. این سلول‌ها هزینه تولید کمتری

در پی تقاضای فزاینده جهانی برای انرژی‌های تجدیدپذیر، ساخت و توسعه سلول‌های خورشیدی به عنوان سنگ بنای تولید انرژی پاک، اهمیت بالایی یافته است. به همین منظور تضمین دوام و عملکرد بهینه سلول‌های خورشیدی، معروف به سلول‌های

این مقاله در اردیبهشت‌ماه ۱۴۰۴ دریافت شد؛ در مردادماه بازنگری و در شهریورماه پذیرفته شد.


^۱ فارغ‌التحصیل کارشناسی ارشد، دانشکده مهندسی برق، دانشگاه علم و صنعت، تهران، ایران.

رایانامه: emad_mousavian@alumni.iust.ac.ir

^۲ گروه مهندسی برق، دانشکده مهندسی برق، دانشگاه علم و صنعت، تهران، ایران.

رایانامه: bshkouhi@iust.ac.ir

^۱ Photovoltaic Cell
^۲ Monocrystalline
^۳ Polycrystalline



شکل (۱): نمونه تصاویر EL سلول‌های PV دارای عیب از مجموعه داده ELPV [۶]. الف) سلول مونوکریستال دارای عیب از نوع نقص در ساختار ماده، ب) سلول مونوکریستال دارای عیب از نوع ترک، ج) سلول مونوکریستال دارای عیب از نوع ریزترک، د) سلول پلی‌کریستال دارای عیب از نوع تضعیف اتصال بین سلولی، ه) سلول پلی‌کریستال معیوب از نوع ترک و شکستگی عمیق سلول، و) سلول پلی‌کریستال دارای عیب از نوع ریزترک.

عنوان ورودی، با دقت قابل توجهی معیوب یا سالم بودن آن را مشخص می‌کنند.

تصاویر EL به علت تغییرات در مواد و یا اتصالات با چالش انتشار غیریکنواخت نور از سطح سلول مواجه هستند [۹]. این پدیده منجر به ایجاد نویز ذاتی قابل توجهی در تصاویر می‌شود. پژوهش‌هایی مانند [۱۰] و [۱۱]، نشان داده‌اند که روش‌های سنتی پردازش تصویر می‌توانند این نویز را تا حد زیادی سرکوب کنند. چالش دیگر، تفاوت در فناوری ساخت سلول‌های مونوکریستال و پلی‌کریستال است که منجر به بروز الگوهای عیب متفاوت در تصاویر EL آن‌ها می‌شود. این تفاوت، طراحی یک معماری یکپارچه برای تشخیص دقیق و همزمان نواقص در هر دو نوع فناوری ساخت را به امری دشوار تبدیل می‌کند. اغلب کارهای موجود [۵] تا [۸]، نیز رویکرد خود را تنها بر روی یکی از این فناوری‌ها بهینه‌سازی کرده‌اند.

در این پژوهش، بر این اصل تکیه شده است که تغییرات شدید در مقادیر همسایگی یک پیکسل، نشان‌دهنده وجود یک لبه است. این لبه‌ها می‌توانند ناشی از عیوب، نویز، یا مشخصه‌های ساختاری سلول مانند باس‌بارها باشند. بر این اساس، ما یک فیلتر فوری بالاگذر تنظیم‌شده^۶ را معرفی کرده‌ایم که دو چالش اصلی شناسایی عیوب در تصاویر EL را هدف قرار می‌دهد. همانطور که اشاره شد وجود نویز ذاتی در تصاویر EL می‌تواند منجر به تشخیص نادرست عیوب شود. فیلتر پیشنهاد شده با سرکوب هدفمند نویزها و حذف اطلاعات غیرمفید مانند فرکانس‌های پایین، سیگنال‌های مربوط به لبه‌های عیوب را برجسته می‌سازد. به این ترتیب، با تقویت سیگنال‌های مفید، توجه به محل‌های حساس و مستعد حضور عیب معطوف می‌شود. همچنین، فیلتر پیشنهادی بر ویژگی‌های عمومی عیوب و ساختارها (مانند ترک‌ها و باس‌بارها) تمرکز دارد. این امر وابستگی آن را به یک فناوری ساخت خاص از بین برده و قابلیت تعمیم به هر دو نوع سلول مونوکریستال و پلی‌کریستال را ممکن می‌سازد.

وظیفه فیلتر فوری تنظیم‌شده، تقویت سیگنال‌های فرکانس بالا و همزمان، سرکوب نویزهای ذاتی است. اما تقویت این سیگنال‌ها

دارند اما به دلیل ساختار غیریکنواخت، بازدهی آن‌ها پایین‌تر بوده و معمولاً ظاهری آبی‌رنگ و رگه‌دار دارند [۱].

در فرآیند تولید ماژول‌های PV، که از اتصال سلول‌های متعدد تشکیل می‌شوند، عواملی مانند ترک و شکستگی می‌تواند منجر به ایجاد مجموعه‌ای از عیوب گردد. این عیوب، عملکرد ماژول را کاهش داده و در موارد شدید، ایمنی کل سیستم را به خطر می‌اندازند. روش‌های متداول شناسایی این نواقص شامل تحلیل منحنی‌های جریان-ولتاژ^۱ (I-V) و ترموگرافی مادون قرمز^۲ (IRT) است [۲]. با این حال، این روش‌ها در تشخیص عیوب جزئی مانند ریزترک‌ها، که با گذشت زمان گسترش می‌یابند، محدودیت دارند [۳]. در مقابل، تصویربرداری الکترو لومینسانس^۳ (EL) به‌عنوان یک روش قدرتمند، غیرمخرب و بدون تماس برای شناسایی عیوب مطرح می‌شود [۴]. این راهکار به‌ویژه در تشخیص ریزترک‌ها و سایر ناهنجاری‌های داخلی که با روش‌های دیگر قابل تشخیص نیستند، مؤثر بوده و به مهندسان امکان تشخیص سلول‌های آسیب‌دیده را جهت تعویض آن می‌دهد. شکل (۱)، نمونه تصاویر EL از انواع عیوب در سلول‌های مونوکریستال و پلی‌کریستال را نشان می‌دهد.

تشخیص عیوب از تصاویر EL در روش‌های سنتی مبتنی بر طراحی ویژگی‌های دستی بود. این روش‌ها نیازمند تجربه بالای مهندسی و ویژگی بوده و دقت عملکرد مطلوبی نداشتند. اما با معرفی رویکردهای یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی^۴ (CNN)، پیشرفت چشمگیری در پردازش تصاویر EL و تشخیص هوشمند نواقص با دقت بالا حاصل شد. شبکه‌های CNN به دلیل ظرفیت بالای خود در یادگیری الگوهای پیچیده، توانایی قابل توجهی در شناسایی انواع عیوب و تمایز آن‌ها از مشخصه‌های ساختاری سلول (مانند باس‌بارها^۵) دارند. بر همین اساس، مطالعات مبتنی بر CNN [۵] تا [۸]، با دریافت تصویر EL به

^۱ Current-Voltage

^۲ Infrared Thermography

^۳ Electroluminescence

^۴ Convolutional Neural Networks

^۵ BusBar

^۶ Tuned Fourier High-pass Filter

در روش‌های اولیه پردازش تصویر، ویژگی‌های سلول‌های PV با کمک، تبدیل ویژگی مستقل از مقیاس^۳ (SIFT) [۱۳]، ویژگی‌های مقاوم تسریع‌شده^۴ (SURF) [۱۴]، بافت‌نگار گرادیان‌های جهت‌دار^۵ (HOG) [۱۵]، الگوی باینری محلی^۶ (LBP) [۱۶]، استخراج می‌شد. همچنین، در برخی از پژوهش‌ها [۱۰] و [۱۷]، از انواع فیلترهای پردازش تصویر برای بهبود کیفیت تصویر و حذف نویز استفاده شده است. این روش‌ها بر کاهش نویز و بهبود کیفیت تصویر تمرکز داشتند، اما در شناسایی عیوب کوچک مانند ریزترک‌ها دچار مشکل بودند. در برخی کارها، از فیلتر فوریه برای تشخیص نوسانات فرکانس بالا با هدف حذف باس‌بارها و برجسته‌سازی ترک‌ها استفاده شده است [۱۱]. با این حال، این روش‌های پردازش تصویر سنتی به دلیل وابستگی به پارامترهای تنظیم‌شده دستی، در محیط‌های پیچیده و پس‌زمینه‌های ناممکن عملکرد مطلوبی نداشتند.

۲- روش‌های مبتنی بر یادگیری ماشین

روش‌های یادگیری ماشین نیز در ترکیب با پردازش تصویر، برای شناسایی عیوب به کار گرفته شده‌اند. در برخی از این پژوهش‌ها، از ماشین بردار پشتیبان^۷ (SVM) برای دسته‌بندی عیوب استفاده شده است؛ این روش برای شناسایی ریزترک‌ها بر اساس ویژگی‌های دستی استخراج‌شده از تصویر [۱۸] و یا برای تشخیص نقاط داغ و ریزترک‌ها بر مبنای پارامترهای الکتریکی و محیطی [۱۹] به کار رفته است. اگرچه این رویکردها نسبت به روش‌های سنتی دقت بیشتری دارند، اما همچنان به تنظیم دقیق پارامترها و پردازش دستی نیازمندند. برای رفع این چالش، در پژوهش‌های جدیدتر [۲۰] و [۲۱]، وظیفه استخراج ویژگی به شبکه‌های عصبی عمیق واگذار شده و طبقه‌بندی نهایی توسط الگوریتم‌های یادگیری ماشین انجام می‌شود.

۳- شبکه‌های عصبی کانولوشنی CNN

شبکه‌های CNN به دلیل توانایی بالا در استخراج ویژگی‌های پیچیده، به طور گسترده‌ای برای شناسایی عیوب در تصاویر به کار گرفته شده‌اند. این مدل‌ها با استخراج ویژگی‌های سطحی و عمیق از تصاویر EL، نتایج دقیق‌تری نسبت به روش‌های سنتی ارائه می‌دهند، مانند [۵] تا [۷] و [۲۲]. در پژوهشی دیگر [۲۳]، تصاویر EL با استفاده از پنجره‌های لغزنده به مناطقی در سطح پیکسل تقسیم شده و سپس هر منطقه با یک دسته‌بندی‌کننده مبتنی بر CNN به دو کلاس دارای عیب و بدون عیب طبقه‌بندی شده است. رویکرد دیگر، استفاده از یادگیری جمعی^۸ است [۲۴]. این روش نشان می‌دهد ترکیب نتایج چند مدل با هم می‌تواند به

لزوماً تنها باعث برجسته‌سازی ویژگی‌های عیوب نمی‌شود و از طرفی هم نمی‌توان از اطلاعات سطح بالای تصاویر EL حتی با وجود نویز، چشم‌پوشی کرد. برای حل این چالش، ما مدل FDFNet^۱ را به عنوان یک معماری دوجهی معرفی کرده‌ایم. این مدل علاوه بر دریافت تصویر اصلی EL، نسخه فیلترشده آن (توسط فیلتر فوریه تنظیم‌شده پیشنهادی) را نیز به صورت موازی در شاخه‌ای دیگر پردازش می‌کند. هر شاخه با پردازش سلسله‌ای این داده‌ها، ویژگی‌های سطح پایین تا بالا را استخراج می‌کند و در آخر هم به کمک یک شبکه دسته‌بندی‌کننده، حضور یا عدم حضور عیوب شناسایی می‌شود.

هر یک از دو شاخه مدل، اطلاعات منحصربه‌فردی را استخراج می‌کنند: شاخه تصویر، ویژگی‌های جامع و سطح بالا را در بر دارد، در حالی که شاخه فیلتر، اطلاعات غنی از لبه‌ها و عیوب ارائه می‌دهد. ماهیت مکمل این دو شاخه، این امکان را فراهم می‌سازد که با انتقال ویژگی‌ها بین آن‌ها، هر شاخه به غنی‌سازی اطلاعات شاخه دیگر کمک کند. در همین راستا، مشابه با DCMAF [۱۲]، ماژول ادغام توجه مبتنی بر تمایز DAF^۲ را معرفی کرده‌ایم. این ماژول، ویژگی‌های دو وجه را مقایسه کرده و به صورت هوشمند به وجهی که اطلاعات مفیدتری برای آموزش دارد، توجه بیشتری می‌کند. این فرآیند، انتقال بهینه ویژگی‌ها بین دو شاخه را تضمین می‌نماید.

برای ارزیابی مدل پیشنهادی، از مجموعه داده ELPV [۶] استفاده شده است که شامل گستره وسیعی از عیوب در هر دو نوع سلول مونوکریستال و پلی‌کریستال می‌باشد. پس از آموزش و ارزیابی مدل FDFNet، توانستیم به ترتیب بر روی سلول‌های مونوکریستال و پلی‌کریستال به بالاترین دقت F1-Score وزن‌دار برابر با ۸۹/۷۹٪ و ۸۸/۷۷٪ دست یابیم. از این رو نوآوری‌های کلیدی مقاله عبارت است از:

- سرکوب نویزهای اضافی تصاویر EL با کمک فیلتر فوریه بالاگذر تنظیم‌شده.
- معرفی مدل دوجهی FDFNet به منظور بهره‌مندی هم‌زمان از تصویر EL و تصویر خروجی فیلتر فوریه تنظیم‌شده آن سلول.
- استفاده از ماژول DAF برای ادغام هوشمند و مبتنی بر توجه ویژگی‌های دو شاخه مکمل.

۲- پیشینه تحقیق

در سالیان اخیر توجه به شناسایی عیوب سلول‌های PV افزایش پیدا کرده است و محققان رویکردها و روش‌های مختلفی برای تشخیص و شناسایی آن معرفی کرده‌اند.

۱- روش‌های سنتی پردازش تصویر

^۳ Scale-Invariant Feature Transform

^۴ Speeded Up Robust Features

^۵ Histogram of Oriented Gradient

^۶ Local Binary Pattern

^۷ Support Vector Machine

^۸ Ensemble Learning

^۱ Fourier Discriminative Fusion Network

^۲ Discriminative Attention Fusion

جدول (۱): خلاصه مزایا و معایب انواع روش‌های پیشنهادی تحقیق.

معایب	مزایا	روش
عدم دقت در شناسایی عیوب کوچک و نامنظم	بهبود وضوح تصویر و کاهش نویز	پردازش تصویر سنتی
نیاز به تنظیم پارامترها و پردازش دستی	دقت بالاتر نسبت به روش‌های سنتی، بخش‌بندی دقیق‌تر	یادگیری ماشین
نیاز به حجم داده‌ای و منابع محاسباتی بالا	دقت بالا در شناسایی عیوب، قابلیت یادگیری از داده‌های پیچیده	شبکه‌های عصبی کانولوشنی
پیچیدگی طراحی و نیاز به حجم داده‌ای بیشتر	بهبود دقت شناسایی در محیط‌های پیچیده و پس‌زمینه‌های ناهمگن	مکانیزم‌های توجه
سرعت پایین و هزینه محاسباتی و پیچیدگی آموزشی بالا	شناسایی دقیق و تفکیک نواحی عیوب، دقت بالا	دسته‌بندی-قطعه‌بندی

۳- روش پیشنهادی

در این بخش معماری مدل معرفی شده FDFNet و جزئیات آن تشریح می‌شود. مدل FDFNet از دوشاخه موازی تشکیل شده است که در ورودی، یکی تصویر EL سلول PV و دیگری نسخه فیلترشده آن را دریافت می‌کند. در انتها با یک شبکه دسته‌بندی‌کننده، معیوب و یا سالم بودن سلول ورودی بررسی می‌شود. معماری مدل پیشنهادی که در شکل (۲) نمایش داده شده است، از سه بخش اصلی تشکیل می‌شود: (۱) پردازش فیلتر فوری تنظیم شده، (۲) معماری دو وجهی، و (۳) ماژول توجه مبتنی بر تمایز. در ادامه، هر یک از این بخش‌ها به تفصیل شرح داده خواهند شد.

۳-۱- پردازش فیلتر فوری تنظیم شده

هر سیگنال را می‌توان به صورت مجموعی از موج‌های سینوسی و کسینوسی با دامنه‌ها و فرکانس‌های مختلف نمایش داد که به این نمایش، تبدیل فوری^۲ گفته می‌شود. در پردازش تصویر، این تبدیل امکان انتقال تغییرات فضایی (پیکسلی) به حوزه فرکانس را فراهم می‌سازد که این امر به آشکارسازی لبه‌های تصویر کمک می‌کند. از آنجایی که تصاویر ورودی، دو بعدی و از نوع طیف خاکستری^۴ هستند، این تبدیل باید در دو راستا انجام شود. برای افزایش سرعت محاسبات، در این پژوهش از تبدیل فوری سریع دوبعدی^۵ (FFT)، استفاده شده است. در حوزه فرکانس، تغییرات ناگهانی مقادیر پیکسل‌ها به صورت مولفه‌های فرکانس بالا ظاهر می‌شوند. این مولفه‌ها می‌توانند ناشی از عیوب ساختاری (مانند ترک‌ها)، لبه‌های واقعی قابل انتظار (مانند باس بارها و مرزهای فیزیکی

تشخیص پایدارتر و دقیق‌تری نسبت به یک مدل واحد منجر شود، حتی اگر دقت هر مدل به تنهایی کمتر باشد.

۴- روش‌های مبتنی بر سازوکار توجه^۱

استفاده از سازوکارهای توجه برای شناسایی دقیق‌تر عیوب، به‌ویژه در تصاویر با پس‌زمینه‌های پیچیده، نقش مهمی در افزایش دقت داشته است. تمرکز بر روی ویژگی‌های مهم تصویر و حذف نویزها نیز بهبود قابل توجهی در تشخیص ترک بر روی سلول‌ها به همراه داشته است [۱۱]. همچنین دیگر رویکرد مورد توجه، بهره‌مندی از ماژول توجه سراسری [۲۵] و [۲۶]، به منظور بازنمایی بهتر عیوب بر اساس ویژگی‌های همسایه در تصاویر EL، می‌باشد.

۵- شبکه‌هایی با معماری دسته‌بندی - قطعه‌بندی^۲

روش‌های ترکیبی مبتنی بر معماری‌های دسته‌بندی و قطعه‌بندی مانند [۲۷] و [۲۸] توانسته‌اند با دقت بالاتری نسبت به روش‌های پیشین، ابتدا تصاویر را از نظر وجود ترک‌ها دسته‌بندی کرده و سپس ترک‌های شناسایی شده را قطعه‌بندی کنند. این روش از دقت بالایی برخوردار است اما به دلیل ترکیب دو معماری، با مشکل سرعت پایین و هزینه محاسباتی بالا روبرو است.

در جدول (۱)، خلاصه‌ای از مزایا و معایب روش‌های پیشین ارائه شده است. بر اساس این مرور، برخی پژوهش‌ها از فیلترهای پردازش تصویر برای پیش‌پالایش تصاویر EL بهره برده و خروجی آن را به یک شبکه عصبی عمیق می‌دهند [۱۰] و [۱۱]. اگرچه این رویکرد به کاهش نویز کمک می‌کند، اما باعث تضعیف بخشی از اطلاعات تصویر اصلی می‌شود و در ادامه از تمام ظرفیت شبکه عصبی برای یادگیری ویژگی‌های پیچیده استفاده نخواهد شد. بنابراین، شکاف تحقیقاتی موجود، کمبود رویکردهای یکپارچه‌ای مانند [۲۹] است که به صورت همزمان از مزایای روش‌های سنتی (برای حذف هدفمند نویز) و توانمندی‌های شبکه‌های عمیق (بر روی تصویر اصلی) بهره ببرند. برای پر کردن این شکاف، ما در این مقاله مدل دو وجهی FDFNet را معرفی می‌کنیم. این معماری به صورت همزمان هر دو تصویر اصلی و نسخه فیلترشده را به عنوان ورودی دریافت می‌کند و با ایجاد یک ارتباط مبتنی بر تمایز، از مزایای هر دو وجه بهره می‌برد. این ارتباط که توسط ماژول DAF مدیریت می‌شود، با معطوف کردن توجه مدل به وجه حاوی اطلاعات غنی‌تر، ظرفیت یادگیری الگوهای جامع و پیچیده را افزایش می‌دهد. همچنین، این رویکرد یکپارچه باعث بهبود توانایی مدل در تشخیص دقیق انواع عیوب در فناوری‌های مختلف ساخت سلول‌های خورشیدی می‌شود.

^۲ Fourier Transform

^۴ GrayScale

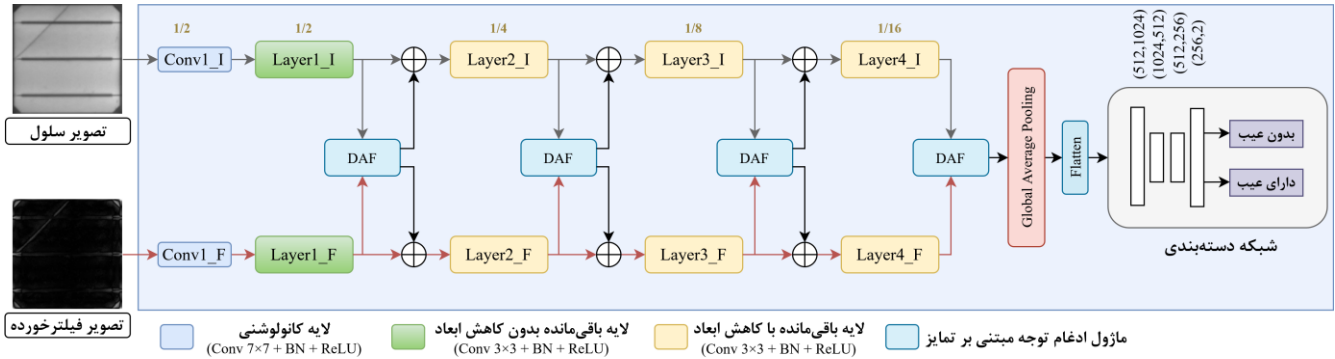
^۵ Fast Fourier Transform

^۱ Attention Mechanism-Based Methods

^۲ Classification-Segmentation Networks

می‌باشد. از سوی دیگر، فرکانس‌های پایین که مربوط به تغییرات آهسته در سطح تصویر هستند، اطلاعات خاصی از عیوب را در بر ندارند. بنابراین، یک راهکار اولیه، اعمال فیلتر بالاگذر برای عبور دادن تنها فرکانس‌های بالا است تا مولفه‌های ضروری مانند عیوب و مشخصه‌های اصلی و واقعی سلول باقی بمانند. با این حال، یک

سلول) و یا نویزهای ناخواسته در تصویر باشند. لبه‌های واقعی قابل انتظار، از الگو مشخصی پیروی می‌کنند و در قیاس با عیوب ساختاری قابل تفکیک هستند. اما نویزهای ناخواسته، منجر به تشخیص نادرست عیوب می‌شوند؛ بنابراین هدف ابتدایی، تفکیک فرکانس‌های بالایی چون عیوب و لبه‌های واقعی سلول، از نویزها



شکل (۲): معماری مدل FDFNet معرفی شده.


و باس بارهای سلول را همراه با کاهش نویز، نشان می‌دهد. در شکل (۳)، نمونه‌ای از تصویر دارای عیب از نوع ترک و ماسک معرفی شده فیلتر فوریه (رابطه (۱)) و خروجی فیلتر، نمایش داده شده است. لازم به ذکر است که پارامتر Δ یک عدد طبیعی و فرد است که پهنای باند فرکانسی حذفی (بر حسب پیکسل) را در تصویر حوزه فرکانس (شکل (۳)، (ج)) مشخص می‌کند. مقدار این پارامتر به مشخصات تصاویر مجموعه داده، به‌ویژه ضخامت باس بارها و الگوی فرکانسی نویز بستگی دارد.

فیلتر بالاگذر استاندارد، قادر به حذف نویزهای ناخواسته تصویر نیست. این نویزها در تصاویر EL به‌خصوص در مرزهای تصویر که عمدتاً محل قرارگیری برخی عیوب است، وجود دارند. از این رو، طراحی یک فیلتر بالاگذر تنظیم‌شده که بتواند به صورت هدفمند این نویزها، به‌خصوص نویزهای مرزی را کاهش دهد، از اهمیت بالایی برخوردار است. بر اساس این نیاز و با انجام آزمایش‌های متعدد، فیلتر زیر پیشنهاد می‌شود.

$$H(u, v) = \begin{cases} 0 & (u, v) \in S(u, v) \\ 1 & (u, v) \notin S(u, v) \end{cases} \quad (1)$$

$$S(u, v) = \left\{ u \in \left(m - \frac{\Delta - 1}{2}, m + \frac{\Delta - 1}{2} \right) \right\} \cup \left\{ v \in \left(n - \frac{\Delta - 1}{2}, n + \frac{\Delta - 1}{2} \right) \right\} \cup \left\{ u \in \left(m - \frac{3}{2}(\Delta - 1), m + \frac{3}{2}(\Delta - 1) \right), v \in \left(n - \frac{3}{2}(\Delta - 1), n + \frac{3}{2}(\Delta - 1) \right) \right\} \quad (2)$$

در رابطه (۱)، فیلتر بالاگذر تنظیم و بهینه‌شده‌ای است که هدف آن، عبور تنها فرکانس‌های بالا با کمترین عبور فرکانس نویزی است، که این شرط را $S(u, v)$ در رابطه (۲) محقق می‌کند. در این روابط، u مبین x (محور افقی تصویر) و v مبین y (محور عمودی تصویر) در حوزه فرکانس می‌باشند. n نشان دهنده نصف ارتفاع تصویر و m نصف عرض تصویر است. تمامی مقادیر u و v که در شرط مجموعه $S(u, v)$ قرار گیرد، به عنوان محدوده فرکانسی در نظر گرفته می‌شود که نباید عبور داده شوند. با اعمال این ماسک و ضرب کانولوشنی آن بر تصویر حوزه فرکانس و همچنین با اعمال تبدیل فوریه معکوس FFT، تصویر خروجی تنها عیب‌های احتمالی



شکل (۳): (الف) تصویر EL سلول PV از نوع مونوکریستال، دارای عیب از نوع ترک. (ب) حوزه فرکانس تصویر (الف). (ج) اعمال ماسک سطری، ستونی و مربع مرکزی بر تصویر (ب) طبق رابطه (۱). (د) خروجی فیلتر فوریه تنظیم‌شده تصویر (الف)، با اعمال تبدیل فوریه معکوس FFT بر (ج).

۳-۲- معماری مدل دو وجهی

می‌شود. سپس همزمان نقشه ویژگی وزن دار شده تصویر را با نقشه ویژگی اولیه شاخه فیلتر و همچنین نقشه ویژگی وزن دار شده فیلتر را با نقشه ویژگی اولیه شاخه تصویر جمع می‌کنیم. نتیجه هر وجه را به بلوک بعدی خود ($L+I$) می‌دهیم. روابط ماژول DAF در زیر آمده است:

$$\begin{aligned} W_L^c(I_L^c, F_L^c) &= \sigma(w_{(1,L)_I}^c(Re(w_{(0,L)_I}^{(c/2)}(I_{(avg,L)}^c)))) - \\ &w_{(1,L)_F}^c(Re(w_{(0,L)_F}^{(c/2)}(F_{(avg,L)}^c))))), \\ F_L' &= F_L^c \otimes (1 - W_L^c(I_L^c, F_L^c)), \\ I_L' &= I_L^c \otimes W_L^c(I_L^c, F_L^c), \\ I_L'' &= F_L' + I_L^c, \quad F_L'' = I_L' + F_L^c. \end{aligned} \quad (3)$$

در رابطه (۳)، پارامترهای $I_{avg,L}^c$ و $F_{avg,L}^c$ به ترتیب بردار میانگین سراسری نقشه‌های ویژگی تصویر (I_L^c) و فیلتر (F_L^c) در سطح L و تعداد کانال c می‌باشند. $\{w_{(0,L)_X}^{(c/2)}, w_{(1,L)_X}^c \mid X \in \{I, F\}\}$ نشان دهنده وزن‌های مستقل دو لایه کانولوشنی 1×1 هستند. W_L^c نیز وزن به دست آمده بعد از اعمال تابع سیگموئید σ ، می‌باشد.

ماژول مذکور، ویژگی‌های دو وجه را در چهار سطح متوالی با یکدیگر ادغام می‌کند. این فرآیند با ایجاد یک ارتباط مبتنی بر توجه و تمایز، اطلاعات منحصربه‌فرد هر شاخه را به شاخه دیگر منتقل کرده تا در بلوک‌های پردازشی بعدی، ویژگی‌های غنی‌تری شکل گیرند. این رویکرد دو مزیت دارد، (۱) از آنجایی که وجه تصویر اصلی دارای اطلاعات غنی زمینه‌ای و وجه فیلتر بر اطلاعات مرتبط با عیوب تمرکز دارد، مدل با وزن‌دهی مبتنی بر توجه، از هر دو نوع اطلاعات برای تمایز دقیق‌تر سلول معیوب از سالم بهره می‌برد، (۲) همچنین اگر ویژگی‌های یک عیب در یک شاخه ضعیف یا ناموجود باشد اما در شاخه دیگر قابل استخراج باشد، این ماژول کانال‌های متناظر دو وجه را مکمل یکدیگر کرده و سیگنال مربوط به حضور عیب را تقویت می‌کند. لازم به ذکر است که ماژول DAF در ۳ سطح ابتدایی به مانند رابطه (۳) عمل می‌کند، اما در آخرین سطح ادغام، به جای جمع نقشه ویژگی‌های وزن دار شده هر وجه با وجه مقابل، دو نقشه ویژگی‌های وزن دار شده F_L' و I_L' تنها با هم جمع می‌شوند و حاصل به لایه میانگین‌گیری سراسری (شکل (۲))، داده می‌شود.

برای بهره‌برداری همزمان از اطلاعات منحصربه‌فرد تصویر اصلی و نسخه فیلتر شده آن، از یک معماری دو شاخه‌ای برای کدگذاری و استخراج ویژگی‌ها استفاده شده است. ستون فقرات هر دو شاخه بر اساس مدل ResNet [۳۰] و با اعمال تغییراتی جزئی طراحی شده که معماری کلی آن در شکل (۲) نمایش داده شده است. هر وجه مدل ResNet از ۴ بلوک باقی‌مانده تشکیل شده است. در ابتدا یک کانولوشن 7×7 بر روی تصویر با گام دو زده می‌شود. سپس از آنجایی که برخی از عیوب سلول‌های PV در ابعاد کوچک اتفاق می‌افتند مانند ریزترک‌ها، ما در اینجا لایه Max-Pooling مدل ResNet را حذف کردیم تا در عمق شبکه ویژگی‌های این نوع از عیوب از بین نرود. به عبارتی گام خروجی ما از ۳۲ به ۱۶ برابر کوچک‌تر از وضوح تصویر ورودی، کاهش پیدا کرده است. در آخر هم نقشه ویژگی^۱ سطح بالا بدست آمده از دو وجه تصویر و فیلتر، در سطح کانال ادغام میانگین‌گیری سراسری^۲ می‌شوند و بردار حاصل به شبکه دسته‌بندی نهایی برای تشخیص وجود یا عدم وجود عیب، داده می‌شود. این شبکه دسته‌بندی از ۴ لایه تماماً متصل تشکیل شده که تعداد آن به صورت تجربی و برای ایجاد تعادل بهینه بین دقت و پیچیدگی محاسباتی انتخاب گردیده است.

۳-۳- ماژول توجه مبتنی بر تمایز

به منظور ایجاد ارتباط بهینه بین دو وجه و انتقال ویژگی‌ها به شاخه‌های متناظر، از ماژول توجه مبتنی بر تمایز (DAF) استفاده شده است. این ماژول ویژگی‌های استخراج شده در سطوح مختلف شبکه را مقایسه کرده و با ایجاد تمایز بین آن‌ها در سطح کانال، به صورت هوشمند توجه خود را به وجهی معطوف می‌کند که نقشه ویژگی آن حاوی اطلاعات غنی‌تر و مفیدتری برای فرآیند آموزش است. معماری این ماژول در شکل (۴)، آورده شده است. به صورت دقیق‌تر، در ابتدا بر روی نقشه ویژگی شاخه تصویر و فیلتر یک لایه ادغام میانگین‌گیری سراسری اعمال می‌کنیم. بردار به دست آمده مبین برآیند اطلاعات موجود در هر کانال است. در ادامه برای هر شاخه، از دو لایه کانولوشن 1×1 مستقل به همراه تابع فعال‌ساز ReLU استفاده می‌شود تا همبستگی بین کانال‌های هر شاخه استخراج شود. به این ترتیب از هر شاخه تصویر و فیلتر، یک بردار بدست می‌آید که بازنمایی از میزان اطلاعات تجمیع شده هر شاخه است. با اختلاف‌گیری بین دو بردار می‌توان تمایز بین دو وجه را در سطح بالاتری انجام داد. در نهایت بردار اختلاف به دست آمده به تابع سیگموئید^۳ داده می‌شود تا بردار وزن بین مقادیر ۰ و ۱ قرار گیرد. بردار وزن (W) و ($I-W$) به ترتیب در نقشه ویژگی اولیه شاخه تصویر و فیلتر در سطح کانال، ضرب

^۱ Feature Map

^۲ Global Average Pooling

^۳ Sigmoid Function

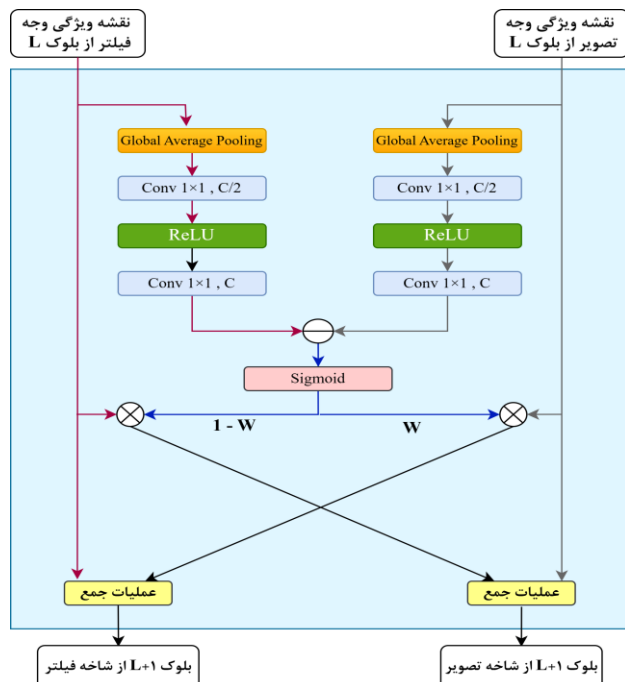
جدول (۲): تعداد داده‌های دارای عیب و سالم مجموعه داده ELPV پس از تقسیم‌بندی به دو دسته آموزشی و تست در دو نوع مونوکریستال و پلی‌کریستال.

مجموعه	شرایط داده	مونوکریستال	پلی‌کریستال
آموزشی	سالم	۵۲۹	۸۲۴
	دارای عیب	۲۷۷	۳۳۹
تست	سالم	۱۷۶	۲۷۴
	دارای عیب	۹۲	۱۱۳

۴-۲- جزئیات پیاده‌سازی

ما تصاویر ورودی را به ابعاد 288×288 تبدیل می‌کنیم تا نسبت صحیحی از گام خروجی مدل ($1/6$) باشند. سپس، تصاویر اصلی و نسخه‌های فیلترشده آن‌ها توسط فیلتر فوریه تنظیم شده (رابطه (۱))، به صورت موازی به عنوان ورودی به دو شاخه مدل داده می‌شوند. این کار به مدل امکان می‌دهد تا در نهایت، وجود یا عدم وجود عیب را در سلول شناسایی کند. در زمان آموزش به منظور بالا بردن تعمیم‌پذیری مدل و جلوگیری از بیش‌برازش^۱، از روش‌های داده‌افزایی مختلفی بهره می‌بریم. این روش‌ها شامل: ۱- بازتاب افقی و عمودی تصادفی که هم زمان بر روی تصویر اصلی و تصویر فیلترشده آن انجام می‌شود، ۲- تغییر تصادفی روشنایی و کنتراست تصویر اصلی به ترتیب در بازه $(1/2, 1/8)$ و $(1/3, 1/7)$ و ۳- اعمال نرمال‌سازی مجزا بر تصویر اصلی و فیلترشده آن به ترتیب با میانگین 0.5968 و 0.1 و انحراف معیار 0.977 و 0.984 . این روش‌های داده‌افزایی به صورت برخط بوده و در حین آموزش بر روی هر دسته آموزشی ورودی اعمال می‌گردند.

ما از مدل ستون فقرات ResNet34 که از پیش بر روی مجموعه داده ImageNet [۳۱] آموزش دیده است، برای هر دو شاخه استفاده کرده‌ایم. مقدار Δ در تابع فیلتر فوریه (رابطه (۲))، برابر با ۱۱ تنظیم می‌شود. این مقدار به صورت تجربی و با هدف ایجاد بهترین تعادل بین حذف لبه‌های نویزی و حفظ لبه‌های مربوط به عیوب تعیین شده است. اندازه دسته آموزشی و تعداد دوره‌های آموزشی مدل FDFNet نیز به ترتیب برابر با ۶۴ و ۸۰ در نظر گرفته می‌شود. ما از تابع ضرر CrossEntropy به همراه بهینه‌ساز SGD با ابر پارامترهای تکانه 0.9 و کاهش وزن 0.0005 برای منظم‌سازی، استفاده کرده‌ایم. همچنین میزان نرخ یادگیری ابتدایی برابر با 0.006 در نظر گرفته شده است که با سیاست کاهش نرخ آموزشی Polynomial، در طی ۸۰ دور آموزشی با توان 0.9 کاهش می‌یابد. همچنین، به دلیل عدم توازن در تعداد داده‌های سالم و معیوب، برای جلوگیری از سوگیری مدل به سمت کلاس اکثریت (داده‌های سالم)، از روش وزن‌دهی معکوس در



شکل (۴): معماری ماژول DAF.

۴- آزمایش‌ها و نتایج

در این بخش به توضیح محیط آموزشی و عملکرد اجزای مدل معرفی شده FDFNet بر روی مجموعه داده‌ای از تصاویر EL سلول‌های PV می‌پردازیم.

۴-۱- پایگاه داده

ما از مجموعه داده ELPV [۶] برای ارزیابی مدل معرفی شده استفاده کرده‌ایم. این مجموعه داده، ۲۶۲۴ تا تصویر EL از سلول‌های PV با وضوح 300×300 دارد که شامل هر دو نوع مونوکریستال و پلی‌کریستال می‌شود. برچسب‌گذاری این مجموعه داده به صورت احتمال معیوب بودن هر سلول انجام شده است. از آنجایی که ما مانند سایر کارهای انجام شده در این حوزه، با یک مسئله دسته‌بندی روبرو هستیم، نیاز داریم تا این نوع از برچسب‌گذاری را به صورت دسته‌های ۰ و ۱ تبدیل کنیم. برای این کار مجموعه داده را بر اساس احتمال معیوب بودن و با در نظر گرفتن حد آستانه 0.5 ، به دو بخش معیوب (برچسب ۱) و سالم (برچسب ۰) تقسیم می‌کنیم. همچنین به صورت تصادفی ۲۵ درصد از تصاویر کل مجموعه داده را به عنوان مجموعه تست انتخاب می‌کنیم. جدول (۲)، جزئیات تقسیم‌بندی مجموعه داده به دو بخش آموزش و تست را برای هر دو نوع سلول مونوکریستال و پلی‌کریستال نمایش می‌دهد. نسبت حضور داده‌های هر دو برچسب در دو مجموعه آموزشی و تست یکسان است. همچنین نسبت تصاویر سلول از دو نوع مونوکریستال و پلی‌کریستال در دو مجموعه نیز یکسان است تا تعادلی در حضور داده از انواع فناوری‌های ساخت سلول‌های PV، در زمان آموزش و استنتاج داشته باشیم.

^۱Overfitting

جدول (۳): مقایسه مدل معرفی شده در برابر دیگر مدل‌های مشابه بر روی مجموعه داده تست ELPV تحت شرایط یکسان آموزشی.

زمان استنتاج (ms)	F1-Score (%)	Recall (%)	Precision (%)	معماری
۵/۸۴	۶۵/۶۶	۶۰/۳۰	۷۲/۰۷	مدل بینایی [۳۲] (Adapted LeNet5)
۲۱/۲۱	۶۶/۶۳	۶۵/۷۷	۶۷/۵۱	مدل بینایی [۳۳] (Adapted VGG16)
۱۸/۱۱	۶۷/۳۹	۵۸/۶۷	۷۹/۱۶	مدل بینایی [۴] (CNN)
۱۶/۵۹	۶۸/۸۱	۶۰/۲۹	۸۰/۱۴	مدل بینایی [۳۴] (CNN)
۱۹/۱۲	۶۹/۵۳	۶۲/۱۴	۷۸/۹۲	مدل بینایی [۵] (CNN)
۲۳/۸۰	۷۸/۲۲	۷۴/۱۱	۸۲/۸۱	مدل بینایی [۶] (Adapted VGG19)
۱۰/۲۴	۸۴/۳۴	۸۱/۸۶	۸۶/۹۸	مدل بینایی [۳۵] (CNN)
۲۰/۸۳	۸۵/۱۶	۸۲/۰۴	۸۸/۵۳	مدل بینایی [۳۶] (CNN)
۱۴/۵۲	۸۹/۱۷	۸۵/۷۷	۹۲/۸۹	پیشنهادی

جدول (۴): مقایسه مدل معرفی شده در برابر دیگر مدل‌های مشابه تنها در سلول‌های PV مونوکریستال مجموعه داده تست ELPV.

F1-Score (%)	Recall (%)	Precision (%)	معماری
۶۵/۱۹	۵۰/۱۹	۹۳/۰۱	مدل بینایی [۳۴] (CNN)
۷۱/۳۸	۶۵/۱۶	۷۸/۹۱	مدل بینایی [۳۲] (Adapted LeNet5)
۷۴/۷۵	۶۹/۲۵	۸۱/۲۰	مدل بینایی [۵] (CNN)
۷۴/۹۶	۶۶/۴۱	۸۶/۰۴	مدل بینایی [۴] (CNN)
۷۸/۲۰	۷۳/۸۶	۸۳/۱۰	مدل بینایی [۳۳] (Adapted VGG16)
۸۰/۳۴	۷۷/۹۱	۸۲/۹۳	مدل بینایی [۶] (Adapted VGG19)
۸۷/۰۱	۸۳/۷۰	۹۰/۵۹	مدل بینایی [۳۵] (CNN)
۸۶/۷۲	۸۳/۶۱	۹۰/۰۶	مدل بینایی [۳۶] (CNN)
۸۹/۷۹	۸۸/۰۶	۹۱/۵۸	پیشنهادی

تابع ضرر استفاده شده است. بر این اساس، به کلاس‌های دارای عیب و سالم به ترتیب وزن‌های ۳,۱۹۶ و ۱,۴۵۵ اختصاص داده شد. تمامی آزمایش‌ها بر روی دو کارت گرافیک NVIDIA T4 انجام شده است.

۴-۳- معیار ارزیابی

برای ارزیابی از معیار F1-Score استفاده شده است که هم معیار Recall، توانایی مدل در شناسایی عیب و هم معیار Precision، میزان صحیح بودن موارد پیش‌بینی شده به‌عنوان دارای عیب، را شامل می‌شود. از آنجایی که مجموعه داده ELPV از نظر تعداد نمونه‌های سالم و معیوب نامتوازن است، از میانگین وزن‌دار برای محاسبه F1-Score نهایی بهره گرفته شده است. این روش با وزندهی به هر کلاس بر اساس تعداد نمونه‌های آن، اهمیت بیشتری به عملکرد مدل بر روی کلاس اقلیت (دارای عیب) می‌دهد. به عبارت دیگر، اگر عملکرد مدل بر روی کلاس کم‌تعداد ضعیف باشد، این ضعف تأثیر بیشتری بر امتیاز نهایی خواهد گذاشت که منجر به ارزیابی واقع‌بینانه‌تری از مدل می‌شود.

۴-۴- نتایج دسته‌بندی

پس از آموزش مدل FDFNet بر روی مجموعه داده آموزشی ELPV و ارزیابی آن بر روی مجموعه داده تست، نتایج کمی روش پیشنهادی در قیاس با دیگر مدل‌های مشابه در جدول (۳)، آورده شده است. از آنجایی که مدل‌های مشابه معمولاً از تقسیم‌بندی‌های آموزشی متفاوتی برای مجموعه داده ELPV استفاده می‌کنند و برخی نیز از مجموعه داده‌های شخصی برای وزندهی اولیه مدل خود بهره می‌برند، ما مدل‌های آورده شده در جدول (۳) را با تقسیم‌بندی مشابه با کار خودمان آموزش دادیم و نتایج ارزیابی آن‌ها را بر روی مجموعه تست ELPV گزارش کردیم تا بتوانیم مقایسه عادلانه‌ای داشته باشیم. به این ترتیب، مدل ما توانست به F1-Score میانگین وزن‌دار ۸۹/۱۷٪ و به ترتیب به Recall و Precision برابر با ۸۵/۷۷٪ و ۹۲/۸۹٪ دست یابد که نسبت به سایر کارهای بررسی شده، بهبود دقت قابل توجهی را داشته است. علاوه بر این، زمان استنتاج مدل پیشنهادی ۱۴,۵۲ میلی‌ثانیه است که نشان‌دهنده تعادل مطلوب بین دقت بالا و هزینه محاسباتی قابل قبول می‌باشد. همچنین ما برای ارزیابی بهتر عملکرد مدل، در شناسایی عیوب دو نوع سلول مونوکریستال و پلی‌کریستال به ترتیب در جدول (۴) و جدول (۵)، نتایج مدل خود را در قیاس با سایر روش‌ها، آورده‌ایم. همان‌طور که مشاهده می‌کنید، مدل پیشنهادی در هر دو نوع سلول، دقت بالاتری نسبت به سایر روش‌های بررسی شده ارائه می‌دهد. این امر بیانگر تعمیم‌پذیری و عدم سوگیری مدل در شناسایی عیوب، صرف‌نظر از فناوری ساخت سلول‌های PV است.

۴-۶- ارزیابی اجزای اصلی مدل FDFNet

مدل FDFNet معرفی شده از دو شاخه تشکیل شده است که تصاویر اصلی و فیلتر شده را دریافت می‌کند و در ادامه اطلاعات دو شاخه به کمک ماژول DAF در چند سطح با هم ادغام می‌شوند. به این ترتیب، در جدول (۷) مواردی چون، تاثیر اعمال فیلتر فوری، دو شاخه‌ای شدن معماری مدل و حضور چند سطحی ماژول ادغام DAF را بررسی می‌کنیم. همان‌طور که مشاهده می‌کنید، زمانی که ما از یک معماری تک شاخه با ورودی تصویر اصلی EL سلول، استفاده می‌کنیم به دقت F1-Score پایین ۸۱/۴۳٪ دست پیدا می‌کنیم. اما زمانی که ورودی در همین معماری به خروجی فیلتر فوری تنظیم شده رابطه (۱) تغییر می‌کند، دقت مدل ۲/۰۸٪ افزایش پیدا می‌کند که نشان‌دهنده تاثیر حضور این فیلتر در شناسایی عیوب می‌باشد. در ادامه اگر معماری مدل را به دو شاخه تبدیل کنیم، طوری که ادغام اطلاعات دو وجه در ۴ سطح با عملیات جمع انجام شود و خروجی به بلوک پردازشی بعدی داده شود، مشاهده می‌کنیم که دقت مدل افزایش قابل توجه ۳/۵۱٪ را خواهد داشت. این موضوع نشان می‌دهد، اگر چه فیلتر فوری باعث بهبود عملکرد مدل می‌شود، اما همچنان در شناسایی برخی از عیوب سلول‌ها دچار مشکل است. به همین دلیل، حضور تصویر اصلی EL می‌تواند به مدل کمک کند تا طیف وسیع‌تری از عیوب را شناسایی کند. در ادامه با افزودن ماژول DAF به جای عملیات جمع ساده، با افزایش دقت ۲/۱۵٪ روبرو خواهیم شد. این مورد، اهمیت ادغام ویژگی‌ها به صورت مبتنی بر سازوکار توجه را اثبات می‌کند، چراکه ماژول DAF به صورت پویا به شاخه‌ای که اطلاعات مفیدتری از عیب دارد، وزن بیشتری اختصاص داده و عملکرد نهایی را بهینه می‌سازد.

جدول (۷): ارزیابی تاثیر اجزای اصلی مدل FDFNet. I: ورودی به صورت تصویر EL از سلول. F: ورودی پس از اعمال فیلتر فوری.

معماری	ورودی	F1-Score (%)
تک شاخه	I	۸۱/۴۳
تک شاخه	F	۸۳/۵۱
دو شاخه (ادغام با عملیات جمع)	F و I	۸۷/۰۲
دو شاخه (ادغام با ماژول DAF)	F و I	۸۹/۱۷

۴-۷- ارزیابی تاثیر تغییرات پارامتر Δ

در این بخش حساسیت مدل معرفی شده بر تغییرات پارامتر Δ (رابطه (۲)) بررسی شده است. این پارامتر معرف پهنای پیکسلی مدنظر در تصویر حوزه فرکانس سلول، جهت حذف هدفمند فرکانس‌های پایین و نویزی می‌باشد. انتخاب مقدار این پارامتر به مشخصات تصاویر مجموعه داده بستگی دارد. در جدول (۸) تاثیر

جدول (۵): مقایسه مدل معرفی شده در برابر دیگر مدل‌های مشابه تنها در سلول‌های PV پلی کریستال مجموعه داده تست ELPV.

معماری	Precision (%)	Recall (%)	F1-Score (%)
مدل بینایی [۴] (CNN)	۷۳/۴۱	۵۱/۰۸	۶۰/۲۴
مدل بینایی [۳۲] (Adapted LeNet5)	۶۸/۱۶	۵۷/۴۹	۶۲/۳۷
مدل بینایی [۳۴] (CNN)	۶۶/۸۳	۵۸/۹۹	۶۲/۶۷
مدل بینایی [۳۳] (Adapted VGG16)	۶۷/۵۱	۶۲/۷۳	۶۵/۰۳
مدل بینایی [۵] (CNN)	۷۸/۵۷	۵۹/۲۷	۶۷/۵۶
مدل بینایی [۶] (Adapted VGG19)	۸۳/۱۸	۷۴/۹۸	۷۸/۸۷
مدل بینایی [۳۵] (CNN)	۸۴/۱۱	۸۰/۳۶	۸۲/۱۹
مدل بینایی [۳۶] (CNN)	۸۶/۴۷	۸۱/۹۳	۸۴/۱۴
پیشنهادی	۹۳/۸۴	۸۴/۲۱	۸۸/۷۷

۴-۵- ارزیابی مدل‌های ستون فقرات

در این بخش، عملکرد مدل FDFNet با به‌کارگیری ستون فقرات مختلف از خانواده ResNet، از نظر هزینه محاسباتی و دقت، مورد مقایسه و ارزیابی قرار می‌گیرد. در جدول (۶)، انواع مدل‌های ستون فقرات ResNet از نظر تعداد پارامتر، FLOPs^۱ و زمان استنتاج، مقایسه شده‌اند. همان‌طور که مشخص است، ResNet50 از نظر دقت بالاترین و ResNet18 پایین‌ترین است. از نظر زمان استنتاج اما، ResNet18 توانسته است بالاترین سرعت را داشته باشد. اما در این بین ResNet34 توانسته است از هر دو جنبه سرعت و دقت یک تعادل مناسب ایجاد کند و بهترین عملکرد را در این بین داشته باشد. مدل‌های ResNet101 و ResNet152 به دلیل پیچیدگی بالاتر با مشکل بیش‌برازش روبرو می‌شوند، به همین دلیل در این ارزیابی آورده نشده‌اند.

جدول (۶): مقایسه انواع ستون فقرات ResNet از نظر هزینه محاسباتی، سرعت و دقت در مدل FDFNet.

مدل	پارامترها ($\times 10^6$)	FLOPs ($\times 10^9$)	زمان استنتاج (میلی ثانیه)	F1-Score (%)
ResNet18	۲۴/۲۲	۲۲/۶۵	۱۰/۳۸	۸۶/۲۴
ResNet34	۴۴/۴۳	۴۷/۱۸	۱۴/۵۲	۸۹/۱۷
ResNet50	۶۰/۹۱	۵۳/۲۱	۱۷/۶۳	۸۹/۴۱

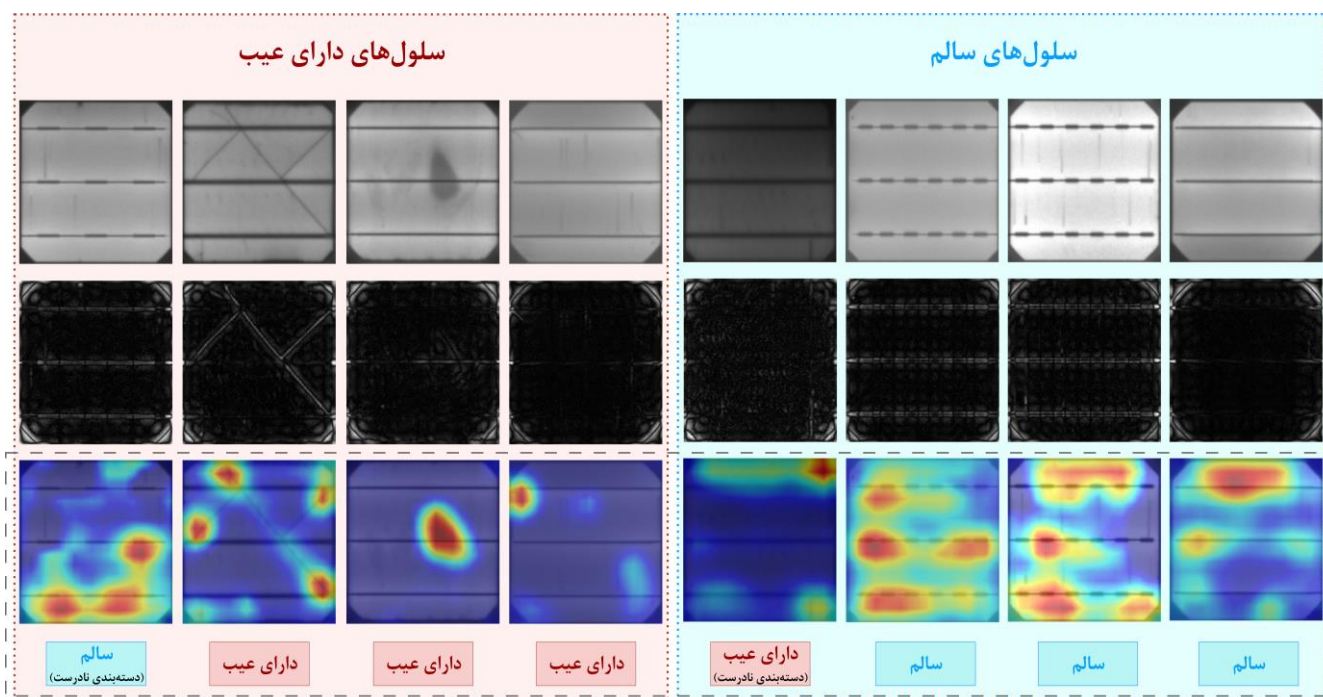
^۱Floating-Point Operations Per Second

۱۱، با ایجاد یک تعادل بهینه بین حذف نویز و حفظ اطلاعات مربوط به عیوب، بهترین عملکرد را ارائه می‌دهد.

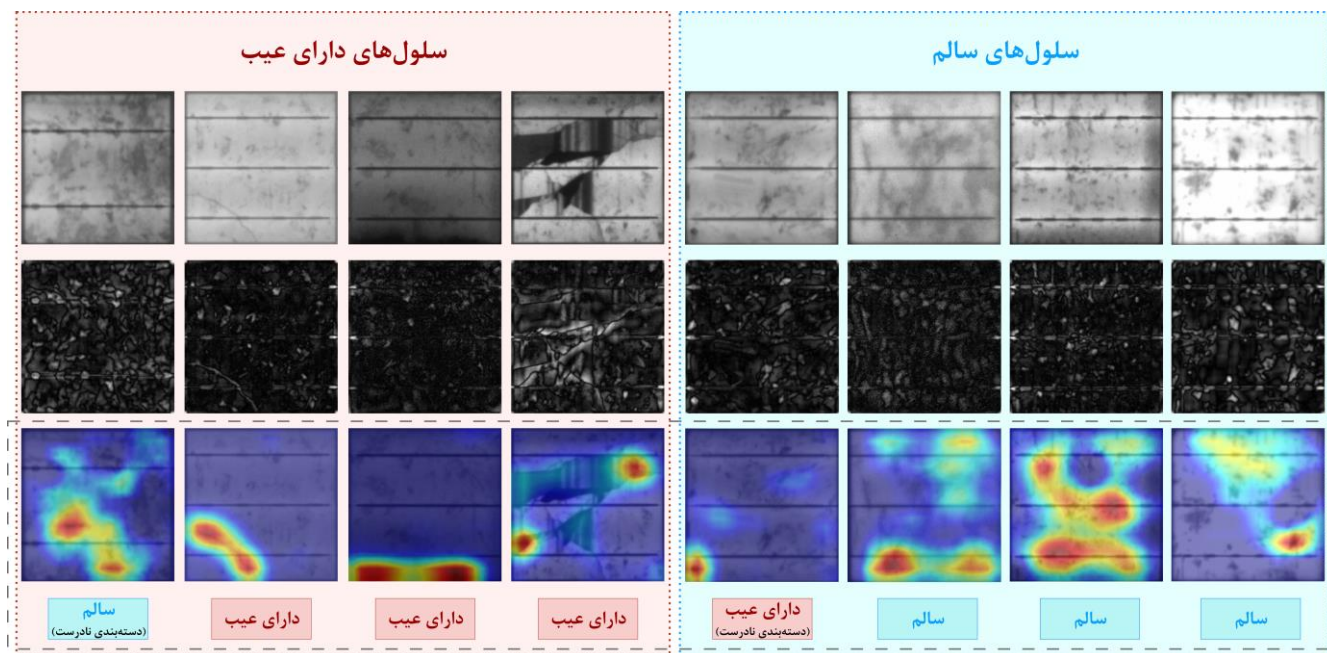
جدول (۸): ارزیابی تاثیر تغییرات Δ در فیلتر فوری تنظیم شده بر دقت مدل FDFNet.

مقدار Δ	(%) Precision	(%) Recall	(%) F1-Score
۳	۹۷/۰۳	۷۸/۹۵	۸۷/۰۶
۷	۹۰/۵۲	۸۶/۸۳	۸۸/۶۴
۱۱	۹۲/۸۹	۸۵/۷۷	۸۹/۱۷
۱۵	۹۵/۱۲	۸۲/۰۴	۸۸/۱۰
۱۹	۸۵/۱۱	۸۸/۱۸	۸۶/۶۲

افزایش و یا کاهش پارامتر Δ بر مدل پیشنهادی FDFNet بررسی شده است. همانطور که نتایج نشان می‌دهد، کاهش مقدار Δ به ۷ و ۳ منجر به افت دقت مدل شده است. دلیل این امر آن است که مقادیر کوچکتر Δ ، منجر به ایجاد یک فیلتر با پهنای باند ناکافی می‌شود که قادر به حذف کامل سیگنال فرکانس قوی نویزها و برخی مشخصه‌های ساختاری و غیر مفید سلول نیست. این اطلاعات باقی مانده می‌توانند باعث سردرگمی شبکه عصبی شوند. به طور مشابه، افزایش بیش از حد مقدار Δ به مقادیر ۱۵ و ۱۹ نیز باعث تضعیف عملکرد مدل می‌گردد. در این حالت، فیلتر تهاجمی‌تر عمل کرده و ریسک حذف فرکانس‌های بالای مربوط به عیوب را افزایش می‌دهد که منجر به از دست رفتن اطلاعات مفید در شاخه فیلتر می‌شود. نتایج نشان می‌دهد که مقدار Δ برابر با



شکل (۵): عملکرد مدل بر روی تصاویر مونوکریستال مجموعه داده تست ELPV بر اساس مناطق مورد توجه با Grad-CAM [۳۷]. تصاویر دو دسته از سلول‌های سالم (بخش آبی) و برجسب دارای عیب (بخش قرمز) مشخص شده‌اند. سطر اول تصویر EL سلول، سطر دوم تصویر فیلتر شده تصاویر سطر اول و سطر سوم نقشه گرمایی مناطق مورد توجه مدل، می‌باشند. در زیر تصاویر سطر سوم پیش‌بینی مدل آورده شده است.



شکل (۶): عملکرد مدل بر روی تصاویر پلی‌کریستال مجموعه داده تست ELPV بر اساس مناطق مورد توجه با Grad-CAM [۳۷]. تصاویر دو دسته از سلول‌های با برجسب سالم (بخش آبی) و برجسب دارای عیب (بخش قرمز) مشخص شده‌اند. سطر اول تصویر EL سلول، سطر دوم تصویر فیلترشده تصاویر سطر اول و سطر سوم نقشه گرمایی مناطق مورد توجه مدل، می‌باشند. در زیر تصاویر سطر سوم پیش‌بینی مدل آورده شده است.

دارای نویز بالایی هستند که می‌تواند بر عملکرد مدل تأثیر بگذارد. در این پژوهش، مدل دو وجهی FDFNet معرفی شده است که تصاویر EL سلول‌های PV را به همراه نسخه فیلترشده آن به صورت هم‌زمان دریافت می‌کند. فیلتر فوریه معرفی شده، با اعمال یک فیلتر بالاگذر تنظیم شده، وظیفه تقویت تغییرات پیکسلی فرکانس بالا (مانند ریزترک‌ها) و هم‌زمان سرکوب نویزها را برعهده دارد. از آنجایی که برخی عیوب دارای فرکانس پایین صرفاً در تصویر اصلی قابل استخراج هستند، با اعمال یک مازول ادغام مبتنی بر تمایز DAF بین دو وجه، به وجهی که ویژگی‌های غنی‌تری از عیب مورد نظر را استخراج کرده است، توجه بیشتری معطوف می‌شود. همچنین در این رویکرد، به دلیل آنکه شاخه تصویر، اطلاعات غنی زمینه‌ای و شاخه فیلتر، اطلاعات مرتبط با عیب را در اختیار دارد، ادغام آن‌ها باعث می‌شود تا دو وجه مکمل یکدیگر شوند. این فرآیند به مدل کمک می‌کند تا با احتمال بیشتری، وجود یا عدم وجود عیب در سلول را شناسایی نماید. برای ارزیابی مدل، از مجموعه داده ELPV استفاده شده است که شامل هر دو نوع سلول مونوکریستال و پلی‌کریستال می‌باشد. بر روی این مجموعه داده، دقت F1-Score وزن‌دار ۸۹٫۱۷٪ به دست آمد و برای سلول‌های مونوکریستال و پلی‌کریستال نیز به ترتیب دقت‌های ۸۹٫۷۹٪ و ۸۸٫۷۷٪ حاصل گردید. نتایج نشان می‌دهد که مدل مذکور توانایی بالایی در تشخیص عیوب در هر دو نوع فناوری متداول ساخت سلول‌های PV دارد.

با وجود نتایج مطلوب، عملکرد مدل در تشخیص عیوبی که فاقد مولفه‌های فرکانس بالا هستند، عمدتاً به شاخه تصویر اصلی متکی بوده و دقت تشخیص همچنان به کیفیت تصویر EL (مانند

۴-۸- ارزیابی سوگیری مدل

برای بررسی سوگیری مدل در شناسایی انواع عیوب، از روش Grad-CAM [۳۷] جهت مصورسازی مناطقی از تصویر که مدل بیشترین توجه را به آن‌ها داشته، استفاده شده است. نمونه‌ای از این تحلیل برای هر دو نوع سلول مونوکریستال و پلی‌کریستال به ترتیب در شکل‌های (۵) و (۶) ارائه شده است. در این شکل‌ها، سطر اول و دوم، ورودی‌های مدل (تصویر اصلی EL و نسخه فیلترشده آن) و سطر سوم، نقشه گرمایی حاصل از Grad-CAM را نمایش می‌دهد. این نقشه، مناطقی را برجسته می‌کند که مدل برای تصمیم‌گیری نهایی خود، بیشترین اطلاعات را از آن‌ها دریافت کرده است. تحلیل نقشه‌های گرمایی نشان می‌دهد که در سلول‌های دارای عیب، توجه مدل به درستی بر روی مناطق حاوی عیب متمرکز شده است. در مورد سلول‌های سالم، توجه مدل به صورت گسترده‌تری بر روی نواحی مختلف سلول توزیع می‌شود. این مشاهدات بیانگر آن است که مدل FDFNet توانسته ویژگی‌های مرتبط با انواع عیوب را در هر دو نوع فناوری با دقت بالایی بیاموزد. در نتیجه، می‌توان گفت مدل پیشنهادی دچار سوگیری نسبت به نوع خاصی از عیوب یا فناوری ساخت سلول نیست.

۵- نتیجه‌گیری

با پیشرفت فناوری و استفاده از شبکه‌های عصبی کانولوشنی و یادگیری عمیق، دقت و کارایی شناسایی انواع عیوب سلول‌های PV به طور چشمگیری افزایش یافته است. اما تصاویر EL سلول‌ها

- [8] X. Chen, T. Karin, and A. Jain, "Automated defect identification in electroluminescence images of solar modules," *Sol. Energy*, vol. 242, pp. 20–29, Aug. 2022.
- [9] Breitenstein, O., Khanna, A., Augarten, Y., Bauer, J., Wagner, J. M., & Iwig, K. "Quantitative evaluation of electroluminescence images of solar cells." *physica status solidi (RRL)–Rapid Research Letters*, 4(1–2), 7–9, 2010.
- [10] K. Yildiz, A. Buldu, M. Demetgul, and Z. Yildiz, "A novel thermal-based fabric defect detection technique," *J. Textile Inst.*, vol. 106, no. 3, pp. 275–283, Mar. 2015
- [11] T. Fan, T. Sun, X. Xie, H. Liu and Z. Na, "Automatic Micro-Crack Detection of Polycrystalline Solar Cells in Industrial Scene," in *Proc. IEEE Access*, vol. 10, pp. 16269–16282, 2022.
- [12] E. mousavian, D. Qashqai and S. B. Shokouhi, "Discriminative Cross-Modal Attention Approach for RGB-D Semantic Segmentation," *Computer and Knowledge Engineering*, 2025, 43–52, doi: 10.22067/cke.2025.88682.1117.
- [13] D. G. Lowe, "Distinctive image features from scale-invariant keypoints," *Int. J. Comput. Vis.*, vol. 60, no. 2, pp. 91–110, 2004, doi: 10.1023/B:VISI.0000029664.99615.94.
- [14] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, "Speeded-up robust features (SURF)," *Comput. Vis. Image Understand.*, vol. 110, no. 3, pp. 346–359, Jun. 2008, doi: 10.1016/j.cviu.2007.09.014.
- [15] 24B24B24BN. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. (CVPR)*, San Diego, CA, USA, Jun. 2005, pp. 886–893, doi: 10.1109/CVPR.2005.177.
- [16] T. Ojala, M. Pietikäinen, and T. Mäenpää, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," in *Proc. IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, Jul. 2002, doi: 10.1109/TPAMI.2002.1017623.
- [17] O. D. Singh, S. Gupta, and S. Dora, "Segmentation technique for the detection of Micro cracks in solar cell using support vector machine," in *Proc. Multimedia Tools and Applications*, vol. 82, pp. 32091–32116, 2023.
- [18] M. Demant, T. Welschhold, M. Oswald, S. Bartsch, T. Brox, S. Schoenfelder, and S. Rein, "Microcracks in silicon wafers I: Inline detection and implications of crack morphology on wafer strength," in *Proc. IEEE J. Photovolt.*, vol. 6, no. 1, pp. 126–135, Jan. 2016.
- [19] D.P. Winston, M.S. Murugan, R.M. Elavarasan, R. Pugazhendhi, O.J. Singh, P. Murugesan, M. Gurudhachanamoorthy, E. Hossain, "Solar PV's Micro Crack and Hotspots Detection Technique Using NN and SVM", in *Proc. IEEE Access*, 9, 2021.
- وجود نویز شدید) وابسته است. علاوه بر این، پارامتر Δ در فیلتر فوری به صورت تجربی تعیین شده و به مشخصات مجموعه داده مورد آزمایش، وابسته است. این محدودیت‌ها، چندین مسیر برای تحقیقات آینده هموار می‌سازد. نخست، برای حل مشکل وابستگی پارامتر Δ ، می‌توان به سمت طراحی یک فیلتر فوری تطبیقی حرکت کرد که مقدار بهینه Δ به صورت خودکار و بر اساس مشخصات هر تصویر ورودی تنظیم شود. همچنین، توسعه روش‌های ادغام پیچیده‌تر بین دو وجه برای شناسایی بهتر عیوب با الگوهای ترکیبی و ادغام معماری مدل با سازوکارهای مبتنی بر مبدل^۱ برای استخراج ویژگی‌های جامع‌تر، از دیگر مسیرهای پژوهشی هستند. در نهایت، گسترش معماری فعلی به یک سیستم قطعه‌بندی معنایی^۲ به منظور تعیین دقیق مکان و شکل عیوب، پتانسیل آن را دارد که بهره‌وری صنعتی این رویکرد را به شکل چشمگیری افزایش دهد.

مراجع

- [1] Supriyono, Toto, Ghazali Omar, Noreffendy Tamaldin, Priyono Soetikno, Muhammad Rizki Sumartono, Angesta Romano, and Mohamad Yamin. "Performance comparison of monocrystalline and polycrystalline photovoltaic modules before testing with a cooling system." *Cogent Engineering* 11, no. 1, 2024, 2430426.
- [2] Kajari-Schröder S, Kunze I, Ksntges M. "Criticality of cracks in PV modules." *Energy Procedia* 2012;27:658–63.
- [3] S. Hassan and M. Dhimish, "A Survey of CNN-Based Approaches for Crack Detection in Solar PV Modules: Current Trends and Future Directions," *Solar*, vol. 3, no. 4, pp. 663–683, 2023.
- [4] M. Karimi, J. S. Fada, M. A. Hossain, S. Yang, T. J. Peshek, J. L. Braid, and R. H. French, "Automated pipeline for photovoltaic module electroluminescence image processing and degradation feature classification," *IEEE J. Photovolt.*, vol. 9, no. 5, pp. 1324–1335, Sep. 2019.
- [5] M. W. Akram, G. Li, Y. Jin, X. Chen, C. Zhu, X. Zhao, A. Khaliq, M. Faheem, and A. Ahmad, "CNN based automatic detection of photovoltaic cell defects in electroluminescence images," *Energy*, vol. 189, Dec. 2019, Art. no. 116319.
- [6] S. Deitsch, V. Christlein, S. Berger, C. Buerhop-Lutz, A. Maier, F. Gallwitz, and C. Riess, "Automatic classification of defective photovoltaic module cells in electroluminescence images," *Sol. Energy*, vol. 185, pp. 455–468, Jun. 2019.
- [7] Lu, S. D., Wang, M. H., Wei, S. E., Liu, H. D., & Wu, "Photovoltaic module fault detection based on a convolutional neural network," *Processes*, vol. 9, no. 9, p. 1635, Sep. 2021.

^۱ Transformer

^۲ Semantic Segmentation

- [33] Bartler A, Mauch L, Yang B, Reuter M, Stoicescu L. "Automated detection of solar cell defects with deep learning." In *Proceedings of 26th European signal processing conference (EUSIPCO)*, IEEE, 2018, p. 2035–9.
- [34] Tang W, Yang Q, Xiong K, Yan W. "Deep learning based automatic defect identification of photovoltaic module using electroluminescence images," in *Proc. Sol. Energy*, 2020;201:453–60.
- [35] Zhang, J., Chen, X., Wei, H. and Zhang, K., "A lightweight network for photovoltaic cell defect detection in electroluminescence images based on neural architecture search and knowledge distillation," in *proc. Applied Energy*, 2024, 355, p. 122184.
- [36] Demirci, Mustafa Yusuf, Nurettin Beşli, and Abdülkadir Gümüşçi. "An improved hybrid solar cell defect detection approach using Generative Adversarial Networks and weighted classification." *Expert Systems with Applications* 252, 2024, 124230.
- [37] Selvaraju RR, Das A, Vedantam R, Cogswell M, Parikh D, Batra D. "Grad-CAM: Why did you say that? Visual explanations from deep networks via gradient-based localization." *arXiv preprint*, arXiv:1610.02391, 2016.
- [20] F. Demir, "Enhancing Defect Classification in Solar Panels With Electroluminescence Imaging and Advanced Machine Learning Strategies," in *IEEE Access*, vol. 13, pp. 58481–58495, 2025.
- [21] L. Jasińska, M. Zagórski, J. Domaradzki, M. Maziuk and P. Chodasewicz, "Application of Artificial Intelligence for Selected Photovoltaic Faults Detection Based on Electroluminescence Images," in *IEEE Access*, vol. 13, pp. 126030–126042, 2025.
- [22] Al-Otum, Hazem Munawer. "Classification of anomalies in electroluminescence images of solar PV modules using CNN-based deep learning," in *Solar Energy*, 2024, 112803.
- [23] Balzategui, Julen, Luka Eciolaza, Nestor Arana-Arexolaleiba, Jon Altube, Jean-Philippe Aguerre, Iñaki Legarda-Ereño, and Aitor Apraiz. "Semi-automatic quality inspection of solar cell based on Convolutional Neural Networks." In *Proc. 24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, pp. 529–535. IEEE, 2019.
- [24] Tella, H., Hussein, A., Rehman, S., Liu, B., Balghonaim, A. and Mohandes, M., "Solar photovoltaic panel cells defects classification using deep learning ensemble methods". in *Case Studies in Thermal Engineering*, 2025, 66, p.105749.
- [25] F. M. A. Mazen, R. A. A. Seoud and Y. O. Shaker, "Deep Learning for Automatic Defect Detection in PV Modules Using Electroluminescence Images," in *Proc. IEEE Access*, vol. 11, pp. 57783–57795, 2023.
- [26] Liu, Qing, Min Liu, Chenze Wang, and QM Jonathan Wu., "An efficient CNN-based detector for photovoltaic module cells defect detection in electroluminescence images," in *Solar Energy*, 2024, 112245.
- [27] Y. Jiang and C. Zhao, "Attention classification-and-segmentation network for micro-crack anomaly detection of photovoltaic module cells," in *Proc. Solar Energy*, vol. 238, pp. 291–304, 2022.
- [28] O. D. Singh, A. Malik, V. Yadav, and S. Gupta, "Deep Segmenter system for recognition of micro cracks in solar cell," in *Proceedings of Multimedia Tools and Applications*, vol. 80, no. 5, pp. 6509–6533, 2021.
- [29] H. Gasparyan, S. Agaian and S. Wu, "Efficient Lightweight Networks for Solar Panel Fault Classification Using EL and RGB Imagery," in *IEEE Transactions on Instrumentation and Measurement*, vol. 74, pp. 1–11, 2025, Art no. 3518311.
- [30] He, K., Zhang, X., Ren, S., & Sun, J. "Deep residual learning for image recognition". In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778, 2016.
- [31] Deng, Jia, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. "Imagenet: A large-scale hierarchical image database." in *Proc. IEEE conf. compu. Vis. pattern recognit.*, 2009, pp. 248–255.
- [32] Sun M, Lv S, Zhao X, Li R, Zhang W, Zhang X. "Defect detection of photovoltaic modules based on convolutional neural network. In: International conference on machine learning and intelligent communications," in *Springer*, 2017, p. 122–32.

سیدعماد موسویان در سال ۱۴۰۰ مدرک کارشناسی خود را در رشته مهندسی برق از دانشگاه شهید بهشتی تهران دریافت کرد. سپس، مدرک کارشناسی ارشد خود را در رشته مهندسی برق گرایش سیستم های الکترونیک دیجیتال از دانشگاه علم و صنعت در سال ۱۴۰۳ دریافت کرده است. زمینه تحقیقاتی وی شامل یادگیری ماشین و هوش مصنوعی است و تحقیقات متعددی در حوزه های مختلف بینایی کامپیوتر از جمله، قطعه بندی معنایی در صحنه های رانندگی، تشخیص اشیا دو بعدی و سه بعدی و تشخیص تغییرات فضای سبز داشته است.



شهریار برادران شکوهی مدارک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی برق و الکترونیک به ترتیب در سال های ۱۳۶۵ و ۱۳۶۸ از دانشگاه علم و صنعت ایران دریافت کرد. وی مدرک دکترای خود را در رشته مهندسی برق و الکترونیک در سال ۱۳۷۸ از دانشگاه باث انگلستان اخذ نمود. در تیر ۱۳۷۸، وی به دانشکده مهندسی برق دانشگاه علم و صنعت ایران در تهران پیوست. در حال حاضر ایشان عضو هیئت علمی بازنشسته گروه مهندسی برق، عضو گروه الکترونیک و مدیر آزمایشگاه های تحقیقاتی اپتوالکترونیک و بینایی ماشین می باشند. علایق پژوهشی وی شامل طراحی سیستم های بینایی ماشین، طراحی سخت افزار قابل اعتماد و طراحی سیستم های هوشمند است.

