

Fault Diagnosis and Detection in Photovoltaic Systems Using Neural Network VGG16

Samaneh Azimi¹, Mohammad Manthouri^{2*}, Mahdi Akhbari³

¹ Department of Electrical Engineering, Shahed University, Tehran, Iran

² Department of Electrical Engineering, Shahed University, Tehran, Iran

³ Department of Electrical Engineering, Shahed University, Tehran, Iran

Received: 14 March 2023, Revised: 17 October 2023, Accepted: 27 November 2023

Paper type: Research

Abstract

Fault detection in photovoltaic (PV) arrays is necessary to increase the output power and also the useful life of a PV system. The presence of conditions such as partial shade, high impedance faults, and the maximum power point detector (MPPT) system make the fault detection of PV in environmental conditions more challenging. The literature identified and classified defects just in few scenarios. In this study two-dimensional scalograms are generated from PV system data. The VGG16 as a pre-trained convolutional neural network is used for feature extraction. Finally, to identify and classify faults in the PV system a fully connected neural network is trained. Unlike the previous methods proposed in the literature on the subject of defect detection and classification, various defective cases with MPPT combination are considered in this research. It has been shown that the proposed method including pre-trained CNN performs better than the existing methods and achieves an error detection accuracy of 83.375%.

Keywords: Photovoltaic array, Maximum power point tracking, Fault classification, Convolutional neural network, Scalograms

* Corresponding Author's email: mmanthouri@shahed.ac.ir

تشخیص و شناسایی خطا در سیستم‌های فتوولتائیک با استفاده از شبکه عصبی عمیق VGG16

سمانه عظیمی^۱، محمد منثوری^{۲*}، مهدی اخباری^۳

^۱ گروه قدرت، دانشکده فنی مهندسی، دانشگاه شاهد، تهران، ایران

^۲ گروه کنترل، دانشکده فنی مهندسی، دانشگاه شاهد، تهران، ایران

^۳ گروه قدرت، دانشکده فنی مهندسی، دانشگاه شاهد، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۱۲/۲۳ تاریخ بازبینی: ۱۴۰۲/۰۷/۲۵ تاریخ پذیرش: ۱۴۰۲/۰۹/۰۶

نوع مقاله: پژوهشی

چکیده

تشخیص خطا در آرایه‌های فتوولتائیک (PV) برای افزایش توان خروجی و همچنین طول عمر مفید یک سیستم PV ضروری است. وجود شرایطی مانند سایه جزئی، خطاهای امیدانس بالا و وجود سامانه ردیاب نقطه حداکثر توان (MPPT)، تشخیص خطا را در شرایط محیطی به چالش می‌کشد. بیشتر تحقیقات انجام‌شده در این زمینه فقط در چند سناریو از عیوب به شناسایی و طبقه‌بندی پرداخته‌اند و اکثراً نیاز به تجهیزات پیشرفته (تصویرساز حرارتی، پهپادها) برای اکتساب داده دارند که روش اکتساب داده این پژوهش به وسیله اسکالوگرام‌های دوبعدی این نیاز را مرتفع کرده است. این پژوهش با استفاده از شبکه‌ی عصبی کانولوشنی عمیق از پیش آموزش داده شده VGG16 و با بهره‌گیری از ویژگی‌های استخراج شده به وسیله اسکالوگرام‌های دوبعدی تولیدشده از داده‌های سیستم PV، به شناسایی و طبقه‌بندی خطا در سیستم PV با استفاده از یک شبکه عصبی کاملاً متصل می‌پردازد. برخلاف روش‌های قبلی پیشنهادشده در ادبیات موضوع تشخیص و طبقه‌بندی عیوب، موارد مختلف معیوب همراه با ترکیب MPPT در مطالعه ما در نظر گرفته شده است. در این تحقیق نشان داده شده است که روش پیشنهادی شامل CNN از پیش آموزش دیده تنظیم شده، از روش‌های موجود بهتر عمل می‌کند و به دقت تشخیص خطای ۸۳/۳۷۵ درصد دست پیدا می‌کند.

کلیدواژه‌گان: آرایه فتوولتائیک، ردیاب نقطه حداکثر توان، طبقه‌بندی خطا، شبکه عصبی کانولوشنی VGG16، اسکالوگرام.

* رایانامه نویسنده مسؤول: mmanthouri@gmail.com

۱- مقدمه

آثار نامطلوب منابع انرژی فسیلی بر سلامت انسان‌ها، تغییرات اقلیمی و اکوسیستم به دنبال رشد صنعتی در سراسر جهان و افزایش مصرف جهانی این نوع منابع لزوم گسترش بهره‌گیری از منابع انرژی‌های تجدیدپذیر را افزایش می‌دهد زیرا این منابع تمیز، پایدار و سازگار با محیط‌زیست هستند. یکی اقتصادی‌ترین منابع انرژی تجدیدپذیر تجاری، انرژی فتوولتائیک خورشیدی است. مزایای متعدد این صنعت نظیر عملکرد عاری از صدا و منبع انرژی با قابلیت دسترسی جهانی سبب توسعه سیستم‌های فتوولتائیک شده است.

بهره‌گیری از سیستم‌های خورشیدی به دلیل کاهش هزینه‌های پنل‌ها و سیاست دولت‌ها به نفع مصرف‌کنندگان به سرعت در حال افزایش است [۱]. تولید برق به میزان ۵۸۰۰ تراوات ساعت تا سال ۲۰۲۵ با توجه به نرخ بهره‌گیری از سیستم‌های فتوولتائیک قابل پیش‌بینی است [۲]. علیرغم مزایا و در دسترس بودن رایگان، صنعت PV به دلیل حضور در شرایط محیطی سخت و وابستگی خطاها به این شرایط با چالش‌هایی از جمله کاهش قدرت خروجی، قابلیت اطمینان و آسیب‌پذیری مواجه است [۳]. با توجه به حضور سیستم‌های PV در محیط بیرونی، امکان وقوع خطاهایی از جمله مدار باز (OC)، خط به خط (LL)، خط به زمین (LG)، نقطه داغ (HS)، افت سیم‌کشی و اثرات زیست‌محیطی (سایه زدن یکنواخت و غیریکنواخت، رطوبت، جمع شدن برف و گردوغبار) در این سیستم‌ها افزایش می‌یابد. این خطاها ممکن است سبب کاهش کارایی و طول عمر PVS شود [۴] و [۵].

پایش سیستم‌های فتوولتائیک به منظور تشخیص به موقع خطاها جهت اطمینان از طول عمر تجهیزات، حداکثر بازده توان و اطمینان از عملکرد قابل اعتماد این سیستم‌ها در مقایسه بزرگ امری ضروری است. روش‌های مختلف نظارت و تشخیص خطا در سرعت، پیچیدگی و سنسورهای موردنیاز و توانایی شناسایی تعداد خطاها متفاوت است. بهره‌گیری از دستگاه‌های محافظتی در قانون ۶۹۰ NCE National Electric Code مانند دستگاه محافظت در برابر خطای زمین (GFPD)^۱، دستگاه محافظت از جریان بیش‌ازحد (OCPD)^۲ و مدار قطع‌کننده خطا قوس (AFCI)^۳ برای بررسی و کاهش انواع خطاها [۶-۹] خود با چالش‌هایی نظیر تابش کم، وجود دیوده‌های مسدودکننده، ردیاب نقطه حداکثر توان (MPPT)^۴ و

ویژگی‌های غیرخطی آرایه‌های PV که مانع از عملکرد صحیح دستگاه‌های محافظت‌کننده‌ی خطا در شرایط مختلف می‌شوند مواجه هستند. از این رو، ممکن است خطاها برای مدت طولانی تداوم‌یافته و قابل‌شناسایی نباشد [۱۰]. بنابراین بهره‌گیری از روش‌های تشخیص عیوب پیشرفته، کارآمد و سازگار با چالش‌های سیستم‌های فتوولتائیک جهت تشخیص به موقع عیوب، افزایش راندمان نیروگاه و طول عمر مفید سیستم امری اجتناب‌ناپذیر است. علاوه بر طرح‌های حفاظتی، روش‌های پیشرفته تشخیص عیب ارائه شده است تا با تشخیص به موقع خطاها، سیستم‌های فتوولتائیک از حفاظت قابل اطمینان برخوردار شوند. اثربخشی روش‌های حفاظت پیشرفته به دلیل خطاهای امپدانس بالا، شرایط آب و هوایی و زمانی که MPPT در حال کار است چالش‌برانگیز است [۱۰]. همچنین روش‌های تشخیص خطا عموماً به تشخیص تعداد محدود از خطاها پرداخته‌اند. به طور خاص [۱۱] به تشخیص فقط یک خطای زمین پرداخته است. همچنین روش پیشنهادی در [۱۲] فقط شامل دو سناریوی خطا در آرایه PV (LLF) و (PS) می‌باشد. طبقه‌بندی چهارخطا (LLF, OCF, SF, BDF)^۵ در [۱۳] مورد بررسی قرار گرفته است.

برای پرداختن به چالش‌های فوق و کمبودهای کار موجود در تشخیص خطا، این مقاله با بهره‌گیری از رویکرد شبکه‌های عصبی کانولوشنی دوبعدی عمیق CNN و با بهره‌گیری از تصاویر اسکالوگرام‌های دوبعدی PV به منظور شناسایی و طبقه‌بندی شش خطای ایجادشده و هم‌زمانی هر شش خطا در سیستم PV پرداخته است. برخلاف تحقیقات جاری، موارد مختلف خطا (از جمله هم‌زمانی انواع خطا، شرایط سایه جزئی، خطای تخریب، خطای زمین، خطا در جعبه اتصال، خطای خط به خط، خطای مدار باز و تجمیع خطاها) با ترکیب MPPT در نظر گرفته شده است. نتایج نشان می‌دهند که روش پیشنهادی این مقاله Fine-Tuned VGG-16 CNN از روش‌های موجود از دقت طبقه‌بندی خطای بالاتری برخوردار است و همچنین قادر به شناسایی تعداد بیشتر خطا چه در سطح آرایه و چه در سطح مازول فتوولتائیک است. همچنین برای استخراج تصاویر به‌عنوان ورودی شبکه عصبی کانولوشنی عمیق نیاز به تجهیزات جانبی مانند تجهیزات تصویربرداری حرارتی ندارد بنابراین روش پیشنهادی نیاز به داده‌های ورودی تصویری برای بهره‌گیری انواع روش تشخیص خطا مبتنی بر یادگیری عمیق را مرتفع

^۴ Maximum Power Point Tracker^۵ Line To Line Fault, Open Circuit Fault, Shading Fault^۱ Ground Fault Protection Device^۲ Over Current Protection Device^۳ Fault Circuit Interrupter

می‌سازد. لذا قادر به بهره‌گیری مستمر در طول شبانه‌روز در یک سیستم خورشیدی بزرگ می‌باشد.

۲- پیشینه پژوهش

روش‌های تشخیص خطای متعددی برای شناسایی و تشخیص خطا در سیستم‌های PV پیشنهاد شده‌اند و طبقه‌بندی‌های متفاوتی برای انواع روش تشخیص خطا با توجه به رویکرد، نیاز حسگر، توانایی تشخیص خطاها، پیچیدگی یکپارچه‌سازی، دقت، هزینه پیاده‌سازی، چالش‌های حفاظتی و محدودیت‌های دستگاه‌های حفاظتی معمولی ارائه شده است.

در تشخیص عیب مبتنی بر یادگیری ماشین، الگوریتم‌های یادگیری ماشین برای یادگیری رابطه بین پارامترهای ورودی و خروجی یک سیستم PV آموزش داده می‌شوند. داده‌های آموزشی را می‌توان به صورت تجربی یا با کمک مدل‌های PV دقیق جمع‌آوری کرد. با این حال، داده‌های غیرعادی در هنگام وقوع خطا نیز برای آموزش و پیش‌بینی دقیق مورد نیاز است [۷].

در ادامه تعدادی از منابعی که با استفاده از روش‌های یادگیری عمیق به تشخیص خطا پرداخته‌اند، بررسی شده و در انتها به صورت خلاصه در جدول ۱ ارائه شده است.

در [۱۴] توسعه یک شبکه عصبی مصنوعی چند خروجی (ANN) را برای تشخیص و شناسایی خطا در سمت DC یک سیستم فتوولتائیک (PVS) ارائه شده است. روش توسعه یافته با استفاده از خروجی طبقه‌بندی، فقط قادر به تشخیص خطاهای مدار باز، اتصال کوتاه و عدم تطابق است.

در [۱۵] خطای خط به خط، خطای زمین و خطای اتصال کوتاه با استفاده از شبکه‌ی عصبی (Bi-LSTM) قابل شناسایی است.

تغییرات در سطح ماژول مانند سوختگی، لایه‌لایه شدن و شکستگی با استفاده از تصاویر هوایی ثبت شده توسط پهپادها و با بهره‌گیری از روش ترکیبی شبکه‌ی عصبی کانولوشنی و (KNN) در [۱۶] تشخیص داده شده است.

در [۱۷] سه نوع خطای زمین، خرابی دیود بای پس و خطای سایه جزئی با استفاده از CNN مبتنی بر ResNet قابل تشخیص است.

در [۱۸] ماژول‌های دارای شکستگی و لایه‌لایه شدن با استفاده از تصاویر هوایی که توسط اینترنت اشیا ارسال و در فضای ابری ثبت

شده‌اند، با استفاده از CNN تشخیص داده می‌شوند.

در مقاله [۱۹] با استفاده از تصاویر ترموگرافی و با بهره‌گیری از شبکه‌ی عصبی CNN ماژول‌های شکسته و دچار لایه‌لایه شدن تشخیص داده شد.

در [۲۰] برای تشخیص ترک بر روی ماژول از تصاویر الکترولومینسانس^۱ و شبکه عصبی عمیق استفاده شده است.

الگوریتم تشخیص خطای مدار باز، خطای اتصال کوتاه و خطا عدم تطابق با ترکیب شبکه‌ی عصبی CNN و SVM در [۲۱] بیان شده است که با دقت خوبی این سه خطا طبقه‌بندی شده‌اند.

جدول ۱. خلاصه پیشینه‌ی تحقیق

| منبع | روش تشخیص خطا | خطاهای تشخیص داده شده |
|------|---------------|---|
| [۱۴] | ANN | خطاهای مدار باز، اتصال کوتاه و عدم تطابق |
| [۱۵] | Bi-LSTM | خطای خط به خط، خطای زمین و خطای اتصال کوتاه |
| [۱۶] | CNN & KNN | سوختگی، لایه‌لایه شدن و شکستگی |
| [۱۷] | CNN | خطای زمین، خرابی دیود بای پس و خطای سایه جزئی |
| [۱۸] | CNN | شکستگی و لایه‌لایه شدن |
| [۱۹] | CNN | شکستگی و لایه‌لایه شدن |
| [۲۰] | DL | تشخیص ترک |
| [۲۱] | CNN & SVM | خطاهای مدار باز، اتصال کوتاه و عدم تطابق |

۳- انواع خطا در آرایه‌ی PV

عواملی که باعث کاهش خروجی یک ماژول یا آرایه PV می‌شوند به عنوان خطا در نظر گرفته می‌شوند. خطاها ممکن است موقت یا دائمی باشند. خطاها در یک سیستم PV می‌توانند به دلایل زیادی رخ دهند، برخی از عواملی که باعث اتلاف انرژی در سیستم‌های PV می‌شوند عبارتند از: تغییر سطح تابش خورشیدی و دمای عملکرد، عدم تطابق در پارامترهای ماژول PV، خطا در ردیابی نقطه حداکثر توان، اثرات سایه، پیری، تجمع برف و گردوغبار روی ماژول‌های PV و خطاهای فاجعه‌بار [۲۲-۲۵]. لذا بینش عمیق برای (۱) تشخیص هر رخداد خطا، (۲) درک ضرورت تشخیص عیب و (۳) تجزیه و تحلیل چالش‌های حفاظتی ضروری است [۲۶]. از این رو برای درک بهتر، تجزیه و تحلیل دقیقی از خطاهای مختلف در این بخش ارائه شده است.

¹ Electroluminescence

۳-۱- خطای تخریب

مهم‌ترین حالت‌های خطای تخریب عبارت‌اند از: شکست جعبه اتصال، شکستن شیشه، اتصال سلولی معیوب، قاب شل و لایه‌لایه شدن. این حالت‌های تخریب در آب‌وهوای گرم و مرطوب بیشتر گزارش شده است [۷]. ورود آب یا رطوبت در یک ماژول PV با شیشه شکسته منجر به تنش خوردگی قابل توجهی می‌شود و باعث تغییر در مقاومت‌های پارازیتی می‌شود [۲۷].

۳-۲- خطای زمین

این پدیده به‌طور تصادفی توسط یک مدار اتصال کوتاه الکتریکی رخ می‌دهد. در واقع، این خطا یک مسیر با امپدانس کم غیر عمدی در میان یکی از هادی حامل جریان و زمین است [۲۸]. خطای زمین اغلب نگرانی‌های ایمنی را در بردارد.

۳-۳- خطای جعبه اتصال

قابلیت اطمینان در جعبه اتصال یکی از حیاتی‌ترین مسائل برای PVM در طول تست تأیید و عملیات در این زمینه است. جعبه اتصال محافظی برای سیم‌کشی از رشته‌ها به پایانه‌های خارجی است. این حالت خرابی می‌تواند ناشی از تثبیت ضعیف جعبه اتصال به صفحه پشتی، نفوذ رطوبت، خوردگی اتصالات، سیم‌کشی ضعیف منجر به قوس داخلی، نصب ضعیف یا به دلیل تخریب حرارتی باشد [۲۹].

۳-۴- خطای خط به خط

خطای خط به خط یک اتصال با مقاومت کم بین دونقطه با پتانسیل مختلف در یک شبکه الکتریکی یا سیستم است. از عوامل ایجادکننده این خطا می‌توان به شکست الکتریکی کابل‌ها، اتصال کوتاه اتفاقی بین هادی‌های انتقال جریان، عایق کم بین اتصالات رشته در جعبه اتصال و آسیب مکانیکی اشاره نمود [۶].

۳-۵- خطای مدارباز

این خطا زمانی اتفاق می‌افتد که یکی از مسیرهای حمل جریان در مسیرهای سری با بار شکسته یا باز شود. از عوامل به وجود آورنده این خطا می‌توان به اتصال ضعیف بین سلول‌ها، قطع و وصل کردن کانکتورها در جعبه اتصال و پارگی سیم‌ها اشاره نمود. وجود خطاهایی نظیر نقطه سوز و خرابی در دیودها نیز از عوامل ایجاد خطای مدارباز به شمار می‌روند [۲۸].

۳-۶- سایه و نیم‌سایه

به‌طور کلی دو نوع سایه در سیستم‌های فتوولتائیک تعریف می‌شود. نوع اول سایه سخت که در صورتی رخ می‌دهد که ماژول‌های PV با مواد جامد، به‌عنوان مثال سایه ساختمان‌ها یا گردوغبار، سایه‌دار شده نوع دوم سایه نرم است که ناشی از عناصر موجود در هوا مانند دوده رخ می‌دهد. سایه سخت منجر به کاهش ولتاژ می‌شود؛ زیرا سایه‌دار شدن تعدادی از ماژول‌هایی سری منجر به عدم دریافت تابش یکسان در ماژول‌ها شده و این عامل سبب کاهش جریان اتصال کوتاه ماژول‌های سایه‌دار می‌شود. ماژول‌هایی که سایه‌دار نشده‌اند جریان اتصال کوتاه بالاتری دارند و می‌خواهند جریان تولیدی بیشتر را عبور دهد سری بودن این ماژول‌ها سبب می‌شود که ماژول‌های سایه‌دار به نقطه‌های اتسپات خود نزدیک شوند. درحالی‌که سایه نرم روی جریان تأثیر می‌گذارد. در صورت عدم رفع سایه شاهد کاهش توان تولیدی و آسیب سلول‌های سایه‌دار خواهیم بود [۶].

۴- شبیه‌سازی آرایه فتوولتائیک


با توجه به رشد سریع در منابع انرژی تجدیدپذیر به‌خصوص درزمینه‌ی سیستم‌های خورشیدی، طراحان PV به یک ابزار قابل‌اطمینان و انعطاف‌پذیر برای پیش‌بینی تولید برق توسط سیستم‌های PV در اندازه‌های مختلف نیاز دارند. مدل PV خورشیدی به‌طور بی‌وقفه به‌روز می‌شود تا به محققان برای درک بهتر عملیات کمک کند. بیشتر مدل‌های ریاضی بر اساس روابط ولتاژ-جریان مبتنی بر مدل تک دیودی یا دو دیودی گسترش یافته‌اند.

۴-۱- مدل ریاضی ماژول فتوولتائیک


ماژول فتوولتائیک از سلول‌های فتوولتائیک تشکیل شده است که به‌طور موازی به هم متصل می‌شوند. این سلول اساساً یک اتصال p-n است که از نیمه رسانایی مانند سیلیکون ساخته شده است که امکان تبدیل انرژی نور به برق را فراهم می‌کند. همان‌طور که در شکل ۱ نشان داده شده است. یک سلول PV ایده آل به‌صورت مدار تک دیودی مدل می‌شود [۳۰].

مدار معادل که شامل منبع فتوجریان، دیود، مقاومت موازی بیان‌کننده جریان شنت و مقاومت سری است که مقاومت داخلی در برابر جریان را توصیف می‌کند. معادله مشخصه I-V یک سلول PV با روابط (۱) تا (۴) تعیین می‌شود [۳۰].

ولتاژ مدار باز ۳۹/۵




شکل ۲. نمودار P_V در حالت تابش متغیر-دما ثابت



شکل ۳. نمودار P_V در حالت تابش ثابت-دما متغیر

شکل ۴ پیکربندی سیستم PV را در حالت‌های خطای مختلف را نشان می‌دهد. سیستم فتوولتائیک طراحی شده از یک آرایه ۴×۵ با ۲۰ ماژول ۳۰۰ وات با توان خروجی ۶ کیلووات تشکیل شده است. شکل ۵ مدل سیمولینک کل سیستم PV را با استفاده از مدل تک دیود مرجع مطابق با مرجع [۳۰] نشان می‌دهد که شامل مبدل تقویت‌کننده DC-DC با MPPT برنامه‌ریزی شده با الگوریتم اغتشاش و مشاهده (P&O) می‌باشد.



شکل ۱. مدار معادل سلول PV [۲۸]

جریان نوری:

$$I_{ph} = [I_{SC} + I_{co}(T_c - T_{rf})] \frac{I_r}{I_{rf}} \quad (1)$$

جریان اشباع معکوس در دمای مرجع:

$$I_{rs} = I_{sc} / [\exp\left(\frac{qV_{oc}}{N_s K A T_c}\right) - 1] \quad (2)$$

جریان اشباع دیود:

$$I_{s=I_{rs}} \left[\frac{T_c}{T_{rf}} \right]^3 \exp\left[\frac{qE_g}{AK} \left(\frac{1}{T_{rf}} - \frac{1}{T_c} \right) \right] \quad (3)$$

جریان ماژول PV:

$$I = N_p I_{ph} - N_p I_s \left[\exp\left\{ \frac{qV + IR_s}{N_s K A T_c} \right\} - 1 \right] - \frac{V + IR_s}{R_p} \quad (4)$$

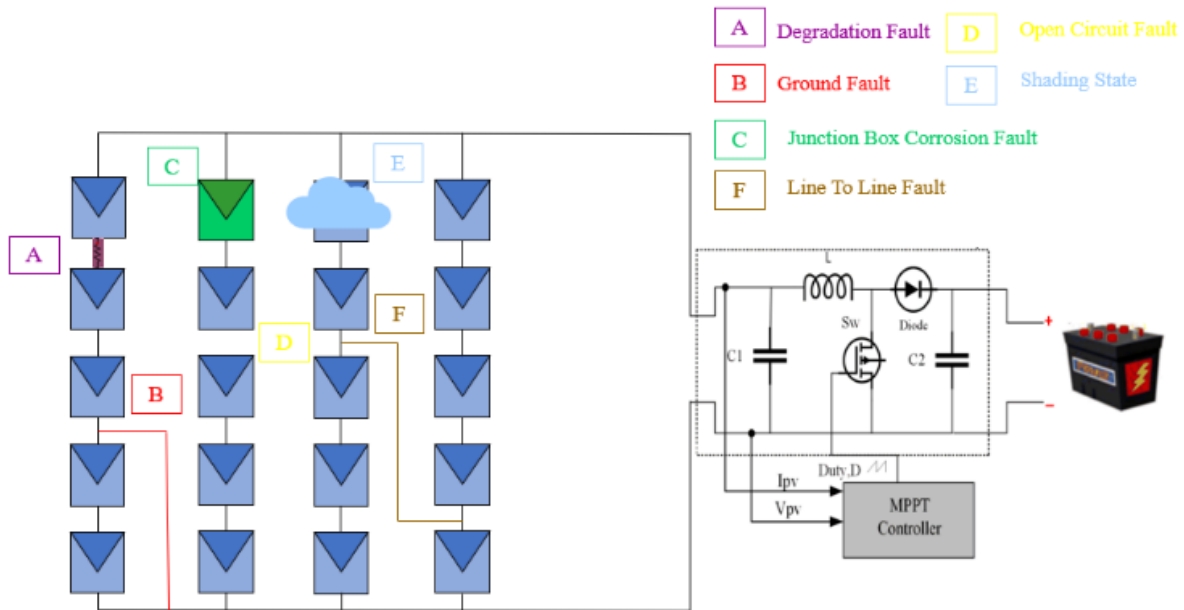
۲-۴-۲ مدل سازی در محیط شبیه‌ساز متلب

پس از مدل کردن سیستم فتوولتائیک در محیط شبیه‌ساز متلب برای اطمینان از عملکرد صحیح سیستم مطابق جدول ۲ مقادیر پارامترهای ماژول PV تحت شرایط تست در حالت استاندارد استخراج شد.


شکل ۲ و ۳ منحنی مشخصه ولتاژ-توان را در دو حالت تابش متغیر-دما ثابت و تابش ثابت-دما متغیر در شرایط عادی نشان می‌دهد.

جدول ۲. پارامترهای ماژول PV تحت شرایط تست در حالت استاندارد

| پارامتر | مشخصات ماژول PV |
|-------------------|-----------------|
| ماکزیمم ولتاژ | ۳۱/۹۸ |
| ماکزیمم جریان | ۹/۴۰۵ |
| ماکزیمم توان | ۳۰۰ |
| جریان اتصال کوتاه | ۱۰/۰۵ |



شکل ۴. انواع خطا در آرایه‌ی خورشیدی



شکل ۵. مدل سیستم PV در محیط شبیه‌ساز متلب

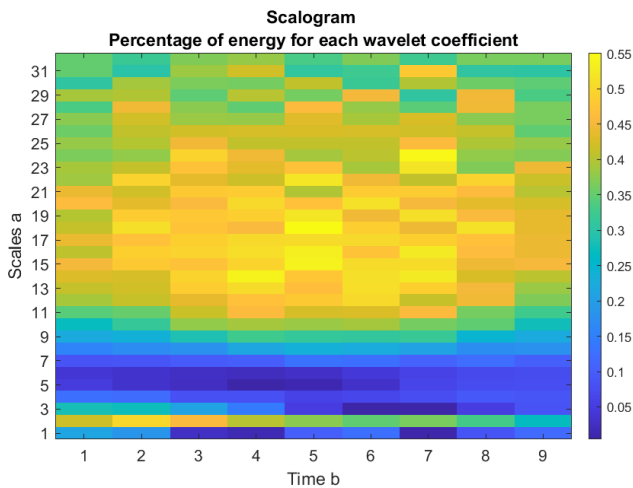
که خطرات ایمنی را نیز دربردارد. داده‌برداری با روش اسکالوگرام که در زمینه‌ی پزشکی از آن استفاده شده علاوه بر افزایش دقت داده‌برداری سایر چالش‌های بیان شده را نیز مرتفع می‌کند

حالت‌های بدون خطا، خطای تخریب، خطای زمین، خطا در جعبه‌ی اتصال، خطای خط به خط، خطای سایه جزئی، خطای مدار باز و تجمیع خطاها، هشت حالت برای ارزیابی روش پیشنهادی در نظر گرفته شده است. داده‌های جمع‌آوری شده شامل تابش (G)، دما (T)، جریان اتصال کوتاه (Isc)، ولتاژ مدار باز (Voc)، جریان فتوولتائیک (Ipv)، ولتاژ فتوولتائیک (Vpv)، جریان MPP (Imp)، ولتاژ MPP (Vmp) و توان MPP (Pmp) است. که ۹ داده مستخرج از خروجی

برای بررسی روش عیب‌یابی پیشنهادی از مدل شبیه‌سازی ارائه شده در شکل ۵ برای جمع‌آوری مجموعه داده تحت شرایط عملیاتی معیوب و غیر معیوب استفاده شده است.

۵- اکتساب داده

روش‌های اکتساب داده اکثراً نیاز به تجهیزات پیشرفته مانند تصویرساز حرارتی، پهپادها و ... دارند که علاوه بر تحمیل هزینه بصورت دوره‌ای داده‌برداری از نیروگاه صورت می‌گیرد که امکان تشخیص خطا در طول این دوره‌ها را با چالش روبه‌رو می‌کند، مخصوصاً برای سه خطای مهم مدار باز، اتصال کوتاه و خطای زمین



شکل ۶. تصاویر اسکالوگرام ورودی شبکه‌ی CNN

از نظر مفهوم شبیه به تبدیل فوریه است اما از خانواده موجک‌ها به‌عنوان توابع پایه خود به‌جای توابع سینوسی و کسینوسی استفاده می‌کند. بیان ریاضی CWT در معادله ۵ آورده شده است که در آن $\psi(t)$ یک نمونه اولیه موجک و $x(t)$ سیگنال اصلی است [۳۱].

$$CWT\{x(t); a, b\} = \int x(t)\psi_{a,b}^*(t)dt \quad (5)$$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}}\psi\left(\frac{t-b}{a}\right)$$

۷- شبکه عصبی کانولوشنی

شبکه عصبی کانولوشنی کلاس خاصی از الگوریتم‌های یادگیری عمیق است. معماری اصلی یک CNN شامل سه لایه اصلی: لایه کانولوشن، لایه ادغام و لایه کاملاً متصل است. عملیات کانولوشن دوبعدی یک نقشه ویژگی بهینه از داده‌های ورودی را با استفاده از تعدادی هسته فیلتر آموخته‌شده تولید می‌کند. لایه ادغام به‌منظور کاهش ابعاد ویژگی داده‌ها عمل می‌کند. در نهایت لایه کاملاً متصل برای طبقه‌بندی استفاده شده است [۳۲].

CNN با استفاده از روش بهینه‌سازی پس انتشار خطا، خطای طبقه‌بندی را بر روی پارامترهای شبکه (به‌عنوان مثال، هسته‌ها/وزن‌های فیلتر) به حداقل می‌رساند. شبکه آموزش داده می‌شود تا ویژگی‌های متمایز را از داده‌های زیربنایی بیاموزد و با استفاده از طبقه‌بندی کننده‌ای مانند لایه softmax منجر به طبقه‌بندی این داده‌ها می‌شود [۱۰].

آرایه PV و ۳ مقدار از مبدل تقویت‌کننده که به‌طور مستقیم یا غیرمستقیم متأثر از وقوع خطا در سیستم PV. تغییر می‌کنند. در مجموع ۱۱۵۲۰ نمونه داده‌ی برچسب‌دار جمع‌آوری شد. هر کلاس دارای ۱۴۴۰ نمونه است که از شبیه‌سازی آرایه PV با ترکیب‌های چندگانه از موقعیت‌های زیر که در جدول‌های ۳ و ۲ نشان داده شده‌اند، استخراج شده است.

جدول ۳. برچسب داده مجموعه داده‌ها

| برچسب داده | زیرسیستم |
|---|------------------------|
| G, T, Isc, Voc, Ipv, Vpv, Imp, Vmp, Pmp | آرایه PV |
| Imax, Vmax, Pmax | مبدل بوست ^۱ |

جدول ۴. مقادیر پارامترهای مجموعه داده

| پارامترها | مقدار هدف |
|-----------|---|
| تابش | ۱۰۰-۱۲۰۰ W/m ² تغییر با گام ۲۰ |
| دما | ۰-۶°C تغییر با گام ۵ |

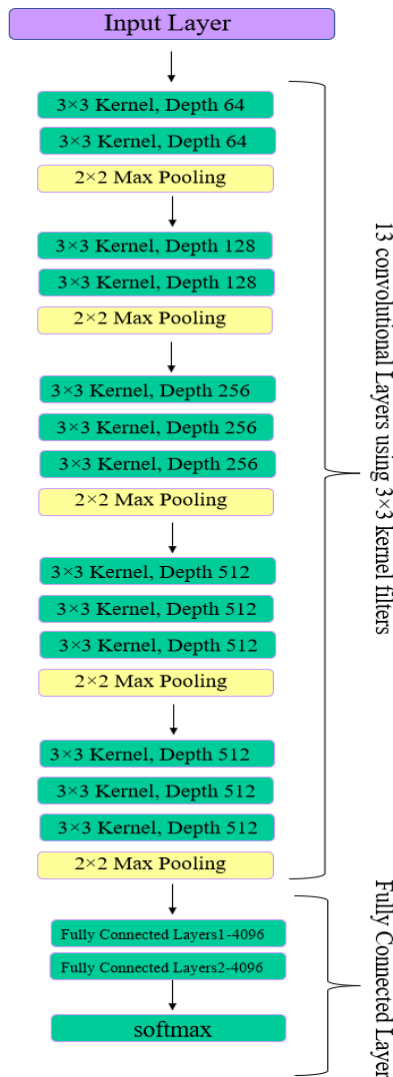
۶- تولید اسکالوگرام دوبعدی^۲

شبکه عصبی کانولوشنی وظایف طبقه‌بندی را مستقیماً از روی تصاویر انجام می‌دهد. امروزه به‌طور گسترده CNN ها در حوزه زیست پزشکی با تبدیل سیگنال‌ها از حوزه زمان (1-D) به حوزه فرکانس (2-D) با استفاده از تبدیل موجک استفاده می‌شوند. داده‌های مستخرج با اعمال تبدیل موجک پیوسته (CWT) سبب تولید اسکالوگرام (تصویر دوبعدی) که در شکل ۶ ارائه شده است می‌شوند. اسکالوگرام یک نمایش بصری سیگنال‌ها بر اساس نمایش زمان-فرکانس با استفاده از تبدیل موجک (WT) است. لازم به ذکر است در این پژوهش به‌منظور افزایش در دقت شبکه عصبی کانولوشنی استفاده شده که به‌طور مستقیم در ارتباط با تعداد داده‌های تصویری ورودی می‌باشد. تصاویر اسکالوگرام با دو وضوح متفاوت استخراج شده است. پس از ایجاد نمودارهای اسکالوگرام برای نمونه داده‌ها در متلب تمام تصاویر اسکالوگرام به‌اندازه استاندارد ۲۲۴ × ۲۲۴ برش داده می‌شوند تا نیاز لایه تصویر ورودی VGG_16 از پیش آموزش دیده را برآورده کنند.

³ Error-Backpropagation

¹ Boost Converter

² 2-D Scalogram



شکل ۷. ساختار شبکه از پیش آموزش داده شده VGG-16

تبدیل موجک پیوسته (CWT) پردازش شده است تا اسکالوگرام‌های دوبعدی تولید شود که به‌طور مؤثر ویژگی‌های فرکانس زمانی داده‌های یک‌بعدی سیستم PV را ضبط کند و داده‌های دوبعدی تولید کند. تصاویر اسکالوگرام اکنون به شکلی هستند که می‌توانند به‌آسانی همراه با یک شبکه عصبی کانولوشنی دوبعدی (2-D CNN) از پیش آموزش دیده برای استخراج ویژگی (در این پژوهش از CNN لایه Sotmax صورت گرفته است. همچنین VGG-16 از پیش آموزش دیده را به‌دقت تنظیم شده است تا یک طبقه‌بندی کننده ۸ طرفه ایجاد کنیم که ویژگی‌ها را استخراج می‌کند و همچنین طبقه‌بندی را در یک چارچوب مشترک انجام می‌دهد. شرح هر مرحله به‌تفصیل در بخش‌های بعدی بیان شده است.

آموزش CNN از ابتدا به مجموعه داده‌های عظیمی برای آموزش نیاز دارد. بنابراین، استفاده از یک شبکه از پیش آموزش دیده توسط مطالعات مختلف توصیه شده است. به‌عبارت‌دیگر، یک شبکه CNN از پیش آموزش دیده بر روی یک مجموعه داده معیار بزرگ که به‌راحتی در دسترس است (مثلاً مجموعه داده ImageNet برای تشخیص اشیا) به‌عنوان یک استخراج‌کننده ویژگی برای هدف قرار دادن یک دامنه متفاوت (مانند خطاهای سیستم PV که در آن تعداد زیادی نمونه آموزشی ممکن است در دسترس نباشد) استفاده شود [۱۰].

۷-۱- شبکه از پیش آموزش داده شده VGG-16

در این پژوهش از VGG-16 CNN از پیش آموزش دیده به‌عنوان الگوریتم استخراج و طبقه‌بندی ویژگی استفاده شده است. ساختار VGG-16 در شکل ۷ نشان داده شده است که شامل ۱۳ لایه کانولوشن و ۲ لایه کاملاً متصل و یک طبقه‌بندی کننده SoftMax است [۳۳].

۸- روش عیب‌یابی پیشنهادی مبتنی بر شبکه عصبی کانولوشنی از پیش آموزش دیده شده

شکل ۸ فلوجارت روش پیشنهادی را نشان می‌دهد. ابتدا، مجموعه‌ای از دیتاست اعمال می‌شود که از مجموع ۱۱۶۴۸ نمونه با ۱۴۵۶ نمونه در هر کلاس تشکیل شده است. این مجموعه داده به‌عنوان یک آزمون ثابت برای ارزیابی رویکرد این پژوهش ارائه شده است تا یک مقایسه معنادار را ایجاد کند. سپس این داده‌های یک‌بعدی با استفاده از تبدیل موجک پیوسته (CWT) پردازش شده است تا اسکالوگرام‌های دوبعدی تولید شود که به‌طور مؤثر ویژگی‌های فرکانس زمانی داده‌های یک‌بعدی سیستم PV را ضبط کند و داده‌های دوبعدی تولید کند. تصاویر اسکالوگرام اکنون به شکلی هستند که می‌توانند به‌آسانی همراه با یک شبکه عصبی کانولوشنی دوبعدی (2-D CNN) از پیش آموزش دیده برای استخراج ویژگی (در این پژوهش از Pretrain VGG-16 CNN استفاده شده است) و طبقه‌بندی بعدی از طریق لایه Sotmax صورت گرفته است. همچنین VGG-16 از پیش آموزش دیده را به‌دقت تنظیم شده است تا یک طبقه‌بندی کننده ۸ طرفه ایجاد کنیم که ویژگی‌ها را استخراج می‌کند و همچنین طبقه‌بندی را در یک چارچوب مشترک انجام می‌دهد. شرح هر مرحله به‌تفصیل در بخش‌های بعدی بیان شده است.

۸-۱- استخراج ویژگی‌های CNN از قبل آموزش دیده

یک ویژگی مهم CNN ها این است که آن‌ها به‌طور خودکار ویژگی‌های طبقه‌بندی‌شده را از داده‌های آموزشی برچسب‌گذاری شده یاد می‌گیرند که طبقه‌بندی را تسهیل می‌کند. همان‌طور که پیش‌تر بیان شد، آموزش مجدد یک CNN از ابتدا نه تنها از نظر محاسباتی گران است، بلکه به مقادیر زیادی داده نیز نیاز دارد. با این وجود، کارهای مختلف در جامعه یادگیری ماشین با موفقیت قدرت تعمیم شبکه‌های عمیق را که از قبل بر روی یک مجموعه داده عظیم انجام شده است، نشان داده‌اند که با توجه به طبقه‌بندی در مجموعه‌های داده دیگر، حتی از حوزه‌های مختلف، عملکرد خوبی دارد. بنابراین، در این پژوهش یک VGG-16 از پیش آموزش داده شده بر روی یک مجموعه داده طبقه‌بندی تصویر در مقیاس بزرگ را برای طبقه‌بندی خطا در آرایه‌های PV اعمال شد. به‌طور خاص، فعال‌سازی‌های نورون‌ها در دومین لایه کاملاً متصل «fc7» آغاز می‌شود که در شکل ۸ نشان داده شده است. به عبارت دیگر برای استخراج بردارهای ویژگی از مدل VGG-16، وزن‌های هر ۵ بلوک کانولوشن منجمد شده و خروجی به دست آمده به طبقه‌بندی جدید داده می‌شود. سپس ویژگی‌های از پیش آموزش دیده VGG-16 CNN به یک لایه طبقه‌بندی ۸ کلاسه مطابق با شکل ۸ منتقل شد.

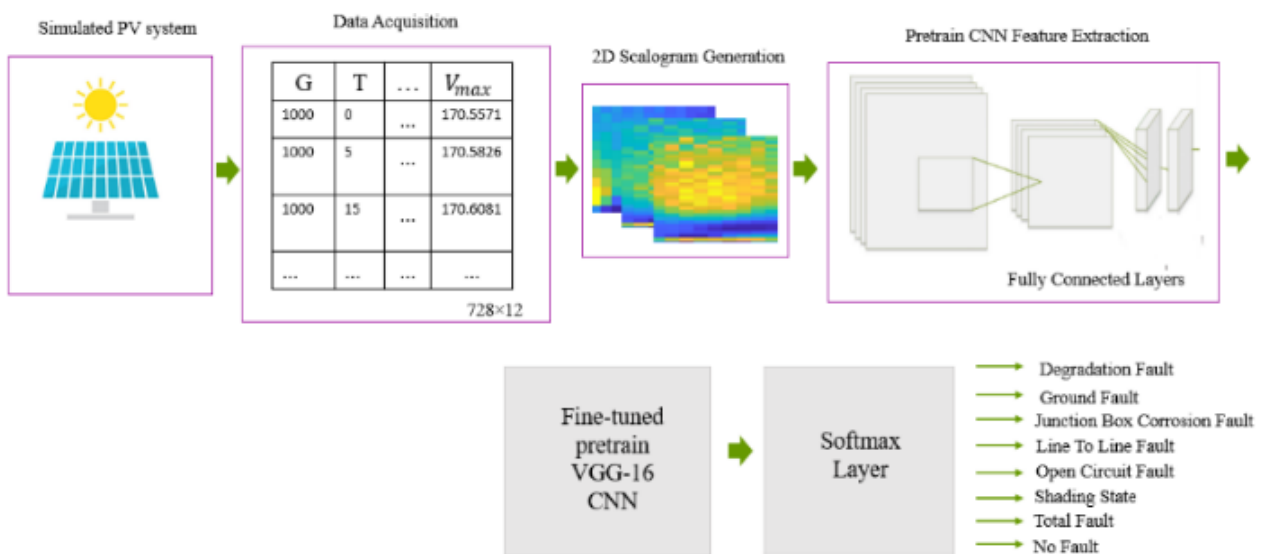
۸-۱-۱ VGG-16 CNN دقیق تنظیم شده

یکی دیگر از تکنیک‌های پرکاربرد برای استفاده مجدد از مدل استخراج ویژگی، تنظیم دقیق است که در شکل ۹ نشان داده شده است. تنظیم دقیق شامل خارج کردن از حالت انجماد چندلایه

بالایی یک پایه مدل منجمد است که برای استخراج ویژگی استفاده می‌شود و آموزش به‌طور مشترک هم بخش جدید اضافه شده مدل (در این مورد، طبقه‌بندی کننده کاملاً متصل) و هم تمام لایه‌های بالایی مجدد آموزش داده می‌شود [۳۴].

تنظیم دقیق لایه‌های بالای پایه کانولوشن یک شبکه از پیش آموزش داده شده تنها زمانی امکان پذیر است که یک طبقه کننده قبل از آن آموزش داده شده باشد در غیر این صورت سیگنال خطای منتشر شده از طریق شبکه در طول آموزش بسیار بزرگ خواهد بود و ویژگی‌هایی که قبلاً توسط لایه‌های کانولوشنی VGG-16 که به خوبی استخراج شده‌اند از بین می‌روند؛ بنابراین مراحل تنظیم دقیق شبکه به شرح زیر است:

۱. داده‌های تصویری را به یک Pretrain VGG-16 CNN که یک لایه طبقه‌بندی به آن اضافه می‌کنیم جهت استخراج ویژگی‌ها اعمال می‌کنیم.
۲. در مرحله دوم Pretrain VGG-16 CNN را منجمد می‌کنیم.
۳. لایه طبقه‌بندی اضافه شده را آموزش می‌دهیم.
۴. بلوک پنجم VGG-16 که شامل دولایه کانولوشن و یک لایه ادغام است را باز کرده است.
۵. در این مرحله لایه باز شده شبکه Pretrain VGG-16 CNN و لایه طبقه‌بندی مجدد آموزش می‌دهیم.



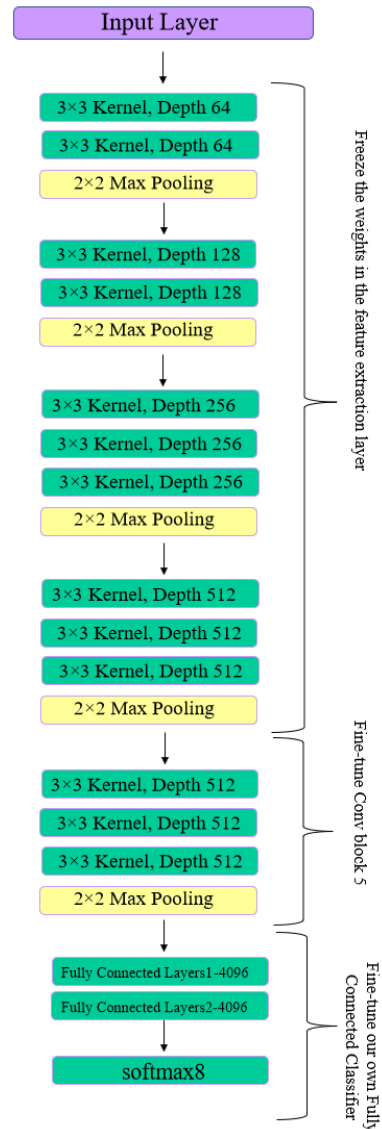
شکل ۸. فلوچارت رویکرد CNN پیشنهادی

استفاده شد. نرخ یادگیری^۵ انتخاب شده ۰/۰۰۰۱ بود. CNN دقیق با ۸۰ درصد داده‌های تصادفی انتخاب شده با ۱۰۰ دوره آموزش^۶ داده شد (یک دوره یک دور کامل آموزش در کل مجموعه داده است). دقت^۷ و ضرر^۸ دو پارامتر مورد استفاده برای ارزیابی عملکرد هستند که در شکل ۱۰ نشان داده شده است. دقت داده‌های آموزش به تدریج افزایش می‌یابد و به حدود ۹۸/۷۳ درصد می‌رسد. با بررسی، می‌توان مشاهده کرد که ضرر به آرامی کاهش می‌یابد و به حدود ۱/۲۷ همگرا می‌شود.

۱۰- تست و ارزیابی

آزمایش بر روی ۲۰ درصد داده‌ها انجام شد و بهترین میانگین دقت و تلفات (بیش از شش اجرای تصادفی)، در هشت کلاس (بدون خطا، خطای تخریب، خطای زمین، خطا در جعبه اتصال، خطای خط به خط، خطای مدارباز و تجمیع خطاها) مشاهده شد. ماتریس درهم ریختگی^۹ در شکل ۱۰ ارائه شده است که دقت هر کلاس (حساسیت) را در امتداد پایین‌ترین ردیف و دقت هر کلاس را در امتداد سمت راست‌ترین ستون نشان می‌دهد. سلول پایین سمت راست، دقت کلی را نشان می‌دهد که در تمام هشت کلاس به‌طور میانگین محاسبه شده است.

برای محاسبه دقت (حساسیت)، دقت یا ویژگی از یک ماتریس درهم ریختگی، ابتدا باید چهار پارامتر TP، FP، TN و FN که به ترتیب بیانگر تعداد مثبت‌های درست، مثبت‌های کاذب، منفی‌های درست و منفی‌های کاذب است را با توجه به یک کلاس خاص از آن محاسبه کنیم. به‌عنوان مثال، ماتریس ارائه شده در شکل ۹ را در نظر بگیرید و فرض کنید که تحلیل برای خطای تخریب است. TP (تعداد نمونه‌های خطای تخریب که به‌درستی به‌عنوان خطای تخریب طبقه‌بندی شده‌اند) ۲۳۵ است؛ و TN (تعداد نمونه‌های نامربوط که به‌درستی به‌عنوان نامربوط طبقه‌بندی شده‌اند) ۴۹ است، FN (تعداد نمونه‌های خطای تخریب که به اشتباه به‌عنوان خطای دیگر طبقه‌بندی شده‌اند) با جمع کردن اعداد در ستون اول (به‌استثنای ردیف اول) عدد ۵۶ حاصل می‌شود.



شکل ۹. تنظیم دقیق آخرین بلوک کانولوشن شبکه VGG16

۹- آموزش و بهینه‌سازی پارامترها^۱

عملکرد الگوریتم‌های DL را می‌توان با تنظیم هایپر پارامترها بهبود بخشید. در این مطالعه چندین ترکیب از مقادیر هایپر پارامتر مورد آزمایش قرار گرفت و بهترین ترکیب اتخاذ شد که در ادامه توضیح داده شده است. حداقل اندازه دسته^۲ روی ۱۰ تنظیم شد تا دقت آموزش افزایش یابد. اندازه دسته به تعداد نمونه‌های آموزشی استفاده شده برای یک تکرار اشاره دارد. نزول گرادیان تصادفی^۳ با مومنتوم^۴ تنظیم شده روی ۰/۸۵ برای تنظیم دقیق CNN دوبعدی

⁶ Epochs

⁷ Accuracy

⁸ Loss

⁹ Confusion Matrix


¹ Training and Hyper-Parameters

² Batch Size

³ Stochastic Gradient Descent

⁴ Momentum

⁵ Learning Rate



شکل ۱۱. دقت طبقه‌بندی با افزایش تعداد کلاس خطاها

۱۱- مقایسه pre-train VGG-16 CNN و سایر روش‌ها

در جدول ۵ مقایسه‌ای بین دقت روش‌های تشخیص خطا و تعداد خطاهای قابل تشخیص مبتنی بر الگوریتم‌های یادگیری عمیق صورت گرفته شده است که تأیید می‌کند روش پیشنهادی این مقاله بالاترین درصد دقت با احتساب تعداد بیشتر خطای تشخیصی را در سیستم PV فراهم می‌کند

جدول ۵. مقایسه دقت طبقه‌بندی روش‌های تشخیص خطا مبتنی بر یادگیری عمیق

| خطای تشخیصی | روش تشخیصی | دقت طبقه‌بندی خطا |
|--|----------------------|-------------------|
| سایه جزئی، خطای تخریب، خطای زمین، خطا در جعبه اتصال، خطای خط به خط، خطای مدار باز و هم‌زمانی خطاها | pre-train CNN VGG-16 | ۸۳/۳۷۵٪ |
| خطاهای مدار باز، اتصال کوتاه و عدم تطابق | ANN [14] | ۷۳/۶٪ |
| خطای خط به خط، خطای زمین و خطای اتصال کوتاه | Bi-LSTM [15] | ۸۰/۱۷۴٪ |
| سوختگی، لایه‌لایه شدن و شکستگی | CNN & KNN [16] | ۹۶/۹۵٪ |
| خطای زمین، خرابی دیود بای پس و خطای سایه جزئی | CNN [17] | ۷۶/۸۲٪ |
| شکستگی و لایه‌لایه شدگی | CNN[18] | ۸۰/۸۴٪ |
| شکستگی و لایه‌لایه شدگی | CNN[19] | ۸۳/۹۱٪ |
| تشخیص ترک | DL[20] | ۹۴/۸۹٪ |
| خطاهای مدار باز، اتصال کوتاه و عدم تطابق | CNN & SVM [21] | ۹۱/۲۳٪ |

| کلاس خرابی | DF | GF | JBF | LLF | NS | OCF | PS | TF | |
|------------|-------|-------|-------|-------|-------|-------|-------|-------|----------|
| DF | 235 | 8 | 5 | 9 | 0 | 3 | 11 | 13 | 82.2% |
| GF | 5 | 196 | 13 | 7 | 1 | 21 | 6 | 17 | 76.0% |
| JBF | 6 | 18 | 232 | 17 | 0 | 9 | 7 | 10 | 82.5% |
| LLF | 8 | 25 | 16 | 190 | 1 | 14 | 10 | 17 | 75.1% |
| NS | 0 | 3 | 0 | 0 | 278 | 1 | 0 | 2 | 97.8% |
| OCF | 6 | 8 | 9 | 27 | 3 | 253 | 5 | 3 | 86.6% |
| PS | 10 | 22 | 10 | 15 | 2 | 8 | 241 | 28 | 84.8% |
| TF | 21 | 11 | 27 | 28 | 4 | 12 | 6 | 233 | 82.0% |
| | 80.7% | 80.3% | 76.8% | 79.5% | 98.6% | 86.6% | 82.8% | 81.2% | 83.375 % |
| | DF | GF | JBF | LLF | NS | OCF | PS | TF | |

DF: Degradation Fault (خطای تخریب) NS: Normal State (بدون خطا)
 GF: Ground Fault (خطای زمین) OCF: Open Circuit Fault (خطای مدار باز)
 JF: Junction Box Corrosion Fault (خطای جعبه اتصال) PS: Partial shading (سایه جزئی)
 LLF: Line To Line Fault (خطای خط به خط) TF: Total Fault (همزمانی تمام خطاها)

شکل ۱۰. ماتریس درهم‌ریختگی، نتایج دقت و ضرر طبقه‌بندی خطا برای VGG-16 CNN از پیش آموزش‌دیده دقیق تنظیم‌شده

توجه داشته باشید که $TP + FN$ برابر است با تعداد کل نمونه‌های مربوطه (تعداد نمونه‌های تست خطای کلاس تخریب)، ثابت است، یعنی ۲۹۱.

بر اساس بحث فوق، دقت یا حساسیت برای خطای کلاس تخریب (پایین‌ترین ستون) برابر است با:

$$TP / (TP + FN) = 235 / (235 + 56) = 80.7\%$$

همچنین دقت یا حساسیت برای خطای کلاس تخریب (راست‌ترین ستون) برابر است با:

$$TP / (TP + FP) = 235 / (235 + 49) = 82.2\%$$

در نهایت میانگین دقت ماتریس درهم‌ریختگی نشان‌دهنده دقت تشخیص خطا به روش شبکه عصبی کانولوشنی از پیش آموزش‌دیده شده است که برابر است با ۸۳/۳۷۵٪.

۱۰-۱- افزایش کلاس‌های خطا

عملکرد روش پیشنهادی (VGG-16 با تنظیم دقیق) با افزایش تعداد کلاس‌ها را می‌توان در شکل ۱۱ تجزیه و تحلیل کرد. خطاهایی با شدت جریان خطای کم مانند خطاهای LL به سختی از سایر خطاها تشخیص داده می‌شوند. دقت خطای LL زمانی که سایه جزئی به عنوان کلاس چهارم اضافه می‌شود تا حد قابل توجهی کاهش می‌یابد. در طبقه‌بندی دو کلاس، دقت برای دو کلاس بیش از ۹۰٪ است، اما با افزایش تعداد کلاس‌ها، عملکرد کاهش می‌یابد.

مراجع

- [1] A. Dhoke, R. Sharma, and T. K. Saha, "A technique for fault detection, identification and location in solar photovoltaic systems," *Solar Energy*, vol. 206, pp. 864-874, 2020.
- [2] A. Jäger-Waldau, "Snapshot of photovoltaics—February 2020," *Energies*, vol. 13, no. 4, p. 930, 2020.
- [3] C. Buerhop, D. Schlegel, M. Niess, C. Vodermayr, R. Weißmann, and C. Brabec, "Reliability of IR-imaging of PV-plants under operating conditions," *Solar Energy Materials and Solar Cells*, vol. 107, pp. 154-164, 2012.
- [4] P. B. Quater, F. Grimaccia, S. Leva, M. Mussetta, and M. Aghaei, "Light Unmanned Aerial Vehicles (UAVs) for cooperative inspection of PV plants," *IEEE Journal of Photovoltaics*, vol. 4, no. 4, pp. 1107-1113, 2014.
- [5] J. Tsanakas and P. Botsaris, "An infrared thermographic approach as a hot-spot detection tool for photovoltaic modules using image histogram and line profile analysis," *International Journal of Condition Monitoring*, vol. 2, no. 1, pp. 22-30, 2012.
- [6] D. S. Pillai and N. Rajasekar, "An MPPT-based sensorless line-line and line-ground fault detection technique for PV systems," *IEEE Transactions on Power Electronics*, vol. 34, no. 9, pp. 8646-8659, 2018.
- [7] D. S. Pillai and N. Rajasekar, "A comprehensive review on protection challenges and fault diagnosis in PV systems," *Renewable and Sustainable Energy Reviews*, vol. 91, pp. 18-40, 2018.
- [8] Y. Zhao, J.-F. De Palma, J. Mosesian, R. Lyons, and B. Lehman, "Line-line fault analysis and protection challenges in solar photovoltaic arrays," *IEEE transactions on Industrial Electronics*, vol. 60, no. 9, pp. 3784-3795, 2012.
- [9] B. P. Kumar, G. S. Ilango, M. J. B. Reddy, and N. Chilakapati, "Online fault detection and diagnosis in photovoltaic systems using wavelet packets," *IEEE Journal of Photovoltaics*, vol. 8, no. 1, pp. 257-265, 2017.
- [10] F. Aziz, A. U. Haq, S. Ahmad, Y. Mahmoud, M. Jalal, and U. Ali, "A novel convolutional neural network-based approach for fault classification in photovoltaic arrays," *IEEE Access*, vol. 8, pp. 41889-41904, 2020.
- [11] K. AbdulMawjoed, S. S. Refaat, and W. G. Morsi, "Detection and prediction of faults in photovoltaic arrays: A review," in *2018 IEEE 12th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG 2018)*, 2018, pp. 1-8: IEEE.
- [12] R. Hariharan, M. Chakkarapani, G. S. Ilango, and C. Nagamani, "A method to detect photovoltaic array faults and partial shading in PV systems," *IEEE Journal of Photovoltaics*, vol. 6, no. 5, pp. 1278-1285, 2016.
- [13] M. Catelani, L. Ciani, D. Galar, and G. Patrizi, "Optimizing maintenance policies for a yaw system using reliability-centered maintenance and data-driven condition monitoring," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 9, pp. 6241-6249, 2020.
- [14] S. Voutsinas, D. Karolidis, I. Voyiatzis, and M. Samarakou, "Development of a multi-output feed-forward neural network for fault detection in Photovoltaic Systems," *Energy Reports*, vol. 8, pp. 33-42, 2022.
- [15] Z. Mustafa, A. S. Awad, M. Azzouz, and A. Azab, "Fault identification for photovoltaic systems using a multi-output deep learning approach," *Expert Systems with Applications*, vol. 211, p. 118551, 2023.

در جدول ۵ در منابع [۱۶] و [۲۰-۲۱] دقت تشخیص خطای بالاتری گزارش شده است که به دلیل تشخیص تعداد خطای کمتر و همچنین داده‌برداری در عدم حضور MPPT است که قبلاً نیز بیان شد که وجود MPPT چالشی مهم در تشخیص خطا است.

روش پیشنهادی در منبع [۱۵] بر روی داده‌های بدست آمده در این مقاله شبیه سازی شد تا در شرایط یکسان مقایسه ارائه شود، نتایج شبیه‌سازی با روش Bi-LSTM درصد دقت کمتری برای تشخیص خطاها دارد که در جدول ۶ ارائه شده است.

۱۲- نتیجه‌گیری

در این پژوهش، یک پیکربندی تشخیص خطا مبتنی بر شبکه عصبی کانولوشنی برای طبقه‌بندی خطای آرایه PV پیشنهاد شده است؛ که در آن چندلایه آخر یک VGG-16 از پیش آموزش دیده تنظیم شده است تا خروجی هشت طرفه ایجاد کند. برای طبقه‌بندی روش پیشنهادی ویژگی‌های اساسی یک آرایه PV را برای توسعه الگوریتم طبقه‌بندی خطا بدون استفاده از تجهیزات پیشرفته (تصویرساز حرارتی) اندازه‌گیری می‌کند. علاوه بر این، ارزیابی کمی خطاهای آرایه PV بر اساس روش‌های استخراج و طبقه‌بندی ویژگی برای هشت مورد (بدون خطا، خطای سایه جزئی، خطای تخریب، خطای زمین، خطا در جعبه اتصال، خطای خط به خط، خطای مدارباز و تجمع خطاها) تحت شرایط شدید (که در آن این تعداد خطاها به صورت هم‌زمان در گذشته شناسایی نشده‌اند) انجام شده است. اهم دستاوردهای به دست آمده در این تحقیق عبارت‌اند از: اولاً، یک رویکرد جدید برای طبقه‌بندی خطای آرایه PV با استفاده از تولید اسکالوگرام دوبعدی با وضوح متفاوت که سبب افزایش داده و به تبع آن افزایش تعداد داده‌های آموزش که سبب افزایش دقت طبقه‌بندی خطا شد، ارائه گردید و به دنبال آن با بهره‌گیری از شبکه از پیش آموزش داده شده VGG-16 که به نسبت روش مشابه با شبکه AlexNet که دقت تشخیص خطا بالاتری (۸۳/۳۷۵٪) را ارائه می‌کند، پیشنهاد شده و مورد آزمایش قرار گرفت.

جدول ۶. مقایسه دقت طبقه‌بندی روش پیشنهادی

| خطای تشخیصی | روش تشخیصی | دقت طبقه‌بندی خطا |
|---|-----------------------|-------------------|
| خطای سایه جزئی، خطای تخریب، خطای زمین، خطا در جعبه اتصال، خطای خط به خط، خطای مدارباز و همزمانی خطاها | pre- CNN train VGG-16 | ۸۳/۳۷۵ |
| خطای سایه جزئی، خطای تخریب، خطای زمین، خطا در جعبه اتصال، خطای خط به خط، خطای مدارباز و همزمانی خطاها | Bi-LSTM [15] | ۸۲/۱۷۴ |

- [25] S. R. Madeti and S. Singh, "Online modular level fault detection algorithm for grid-tied and off-grid PV systems," *Solar Energy*, vol. 157, pp. 349-364, 2017.
- [26] M. Dhimish, V. Holmes, B. Mehrdadi, and M. Dales, "Multi-layer photovoltaic fault detection algorithm," *High voltage*, vol. 2, no. 4, pp. 244-252, 2017.
- [27] A. Dhoke, R. Sharma, and T. K. Saha, "PV module degradation analysis and impact on settings of overcurrent protection devices," *Solar Energy*, vol. 160, pp. 360-367, 2018.
- [28] A. Triki-Lahiani, A. B.-B. Abdelghani, and I. Slama-Belkhodja, "Fault detection and monitoring systems for photovoltaic installations: A review," *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 2680-2692, 2018.
- [29] Y.-Y. Hong and R. A. Pula, "Methods of photovoltaic fault detection and classification: A review," *Energy Reports*, vol. 8, pp. 5898-5929, 2022.
- [30] D. Revati and E. Natarajan, "IV and PV characteristics analysis of a photovoltaic module by different methods using Matlab software," *Materials Today: Proceedings*, vol. 33, pp. 261-269, 2020.
- [31] A. Narin, "Detection of focal and non-focal epileptic seizure using continuous wavelet transform-based scalogram images and pre-trained deep neural networks," *Irbm*, vol. 43, no. 1, pp. 22-31, 2022.
- [32] J. Garcia, S. Muller, E. Caicedo, T. Bastos Filho, and A. Souza, "Non-fatigating brain computer interface based on SSVEP and ERD to command an autonomous car," *Advances in Data Science and Adaptive Analysis*, vol. 1, pp. 1-11, 2018.
- [33] S. Tammina, "Transfer learning using vgg-16 with deep convolutional neural network for classifying images," *International Journal of Scientific and Research Publications (IJSRP)*, vol. 9, no. 10, pp. 143-150, 2019.
- [34] F. Chollet, *Deep learning with Python*. Simon and Schuster, 2021.
- [16] S. N. Venkatesh and V. Sugumaran, "Machine vision based fault diagnosis of photovoltaic modules using lazy learning approach," *Measurement*, vol. 191, p. 110786, 2022.
- [17] A. Mellit, "An embedded solution for fault detection and diagnosis of photovoltaic modules using thermographic images and deep convolutional neural networks," *Engineering Applications of Artificial Intelligence*, vol. 116, p. 105459, 2022.
- [18] S. Naveen Venkatesh *et al.*, "Photovoltaic Module Fault Detection Based on Deep Learning Using Cloud Computing," *Scientific Programming*, vol. 2023, 2023.
- [19] D. Manno, G. Cipriani, G. Ciulla, V. Di Dio, S. Guarino, and V. L. Brano, "Deep learning strategies for automatic fault diagnosis in photovoltaic systems by thermographic images," *Energy Conversion and Management*, vol. 241, p. 114315, 2021.
- [20] A. Sohail, N. U. Islam, A. U. Haq, S. U. Islam, I. Shafi, and J. Park, "Fault detection and computation of power in PV cells under faulty conditions using deep-learning," *Energy Reports*, vol. 9, pp. 4325-4336, 2023.
- [21] S. Voutsinas, D. Karolidis, I. Voyiatzis, and M. Samarakou, "Development of a machine-learning-based method for early fault detection in photovoltaic systems," *Journal of Engineering and Applied Science*, vol. 70, no. 1, p. 27, 2023.
- [22] S. R. Madeti and S. Singh, "A comprehensive study on different types of faults and detection techniques for solar photovoltaic system," *Solar Energy*, vol. 158, pp. 161-185, 2017.
- [23] V. Kongphet, A. Migan-Dubois, C. Delpha, D. Diallo, and J.-Y. Lechenadec, "Photovoltaic Fault Detection and Diagnosis: Which Level of Granularity for PV Modeling?," in *2020 Prognostics and Health Management Conference (PHM-Besançon)*, 2020, pp. 180-186: IEEE.
- [24] M. Köntges *et al.*, "Review of failures of photovoltaic modules," 2014.