

Estimation of Electrical Efficiency of Photovoltaic Panels with Methods Based on Deep Learning Using Image

SeyyedMohammad JavadiMoghaddam*, Hossein Gholamalinejad, Azam Noroozi, Mh Abdi, Hamid Morteza pour

1,2Department of Computer Engineering, Bozorgmehr University of Qaenat, Qaen, Iran,

3Department of Engineering, University of Torbat Heydarieh, Torbat Heydarieh, Iran,

4Department of Physics, Qaenat Branch, Islamic Azad University, Qaenat, Iran,

5Department of Mechanical Engineering, Bozorgmehr University of Qaenat, Qaen, Iran

E-mails: smjavadim@buqaen.ac.ir*; h_gholamalinejad@buqaen.ac.ir; a.noroozi@torbath.ac.ir, abdi@iauq.ir, hmorteza pour@buqaen.ac.ir

Short Abstract

Natural renewable energy sources are abundant and economically attractive, with zero or very low carbon emissions. On the other hand, harsh environmental and weather conditions, such as soil and dust accumulation, affect the efficiency of renewable energy sources and systems. Accordingly, the need for automated inspection of photovoltaic panels is becoming more critical as the demand for new solar energy system manufacturing and installation increases worldwide. This study introduces a new dataset of images of dusty and clean plates. Furthermore, a new convolutional neural network architecture is proposed to detect the voltage generated by the panel. In the following, the parameters taken from the environment and the voltage estimated by the proposed neural network are analyzed using the random forest regression algorithm, and the panel's efficiency is calculated. The proposed process deals explicitly with detecting dust accumulation in photovoltaic panels. The results obtained in this work have experimentally shown that the proposed system produces high detection rates. The proposed new method leads to the implementing of a more effective and efficient automatic cleaning technique for photovoltaic panels.

Keywords

Electrical efficiency, Deep learning, Photovoltaic panels, Convolutional network.

1- Short Introduction

The need for more suitable and balanced datasets makes constructing a model with appropriate parameters challenging, and there is a distinct research gap in evaluating advanced algorithms with suitable datasets. In this paper, a new dataset of dirty and clean images with different levels of dirt has been collected. Furthermore, due to the high cost of cleaning photovoltaic panels, accurate detection of dirty panels is necessary to reduce costs. Therefore, this research presents a method for detecting the electrical efficiency of photovoltaic panels based on deep learning. This research aims to evaluate the proposed method's performance on a new data set.

2- Proposed Work and Methodology

The dataset images were collected at Bozorgmehr Qaenat University in July 1401 from 9:00 AM to 1:00 PM using a Testo 868 camera. The collection of images has been prepared with different levels of dust on the screens and at different radiation intensities. First, the images were converted to grayscale of one channel, and then, to reduce the angle and distance error of the image, a central cut was prepared from it, and its size was changed to a one-channel image of 100x100. The layers of the proposed model include the following. After the input layer, two two-dimensional convolution layers with batch normalization are placed. The convolution layers include 16, 16, 32, and 32 filters with a kernel size 3x32, respectively. A batch normalization layer was used at different network points to reduce the training time for parallel processing. Also, the Max Pooling layer and four random dropout layers were used. The proposed model used Relu for activation functions in hidden layers and Softmax for its output layer. The network parameters were 8483707, training parameters were 8483515, and non-training parameters were 192.

3- Conclusion

Due to the lack of a suitable data set, images with different dirt levels were first prepared in this article. Then, this data set was used to evaluate the proposed structure in two tests. In the first test, the images were classified as clean and dirty. In the second test, regression was used to detect dirty panels. First, the image was converted to an HSV color device. Then, the area containing the photovoltaic panel was specified, and the average saturation value was calculated. For numerical prediction, random forest regression was used. Pearson's correlation value was 0.998, which is very close to one. The paper should be concluded in this section.

4- References

- [1] S. Fan, Y. Wang, S. Cao, B. Zhao, T. Sun, and P. Liu, "A deep residual neural network identification method for uneven dust accumulation on photovoltaic (PV) panels," *Energy*, vol. 239, pp. 122302, 2022.
- [2] K. A. Abuqaoud and A. Ferrah, "A novel technique for detecting and monitoring dust and soil on solar photovoltaic panel," in 2020 *Advances in Science and Engineering Technology International Conferences (ASET)*, IEEE, pp. 1-6, 2020.
- [3] B. M. Das, *Principles of geotechnical engineering*. Cengage learning, 2021. In this section, the main references should be added.

تخمین بازده الکتریکی صفحه‌های فتوولتائیک با روش‌های مبتنی بر یادگیری عمیق با استفاده از تصویر

سید محمد جوادی مقدم

استادیار، گروه کامپیوتر، دانشگاه بزرگمهر قائنات، قاین، ایران

حسین غلامعلی نژاد

استادیار، گروه کامپیوتر، دانشگاه بزرگمهر قائنات، قاین، ایران

اعظم نوروزی

استادیار، دانشکده مهندسی عمران و معماری، دانشگاه تربت حیدریه، تربت حیدریه، ایران

محمدحسن عبدی

استادیار، گروه فیزیک، دانشگاه آزاد اسلامی واحد قاینات، قاین، ایران

حمید مرتضی پور

دانشیار، گروه مکانیک، دانشگاه بزرگمهر قائنات، قاین، ایران

چکیده

منابع انرژی تجدیدپذیر طبیعی، فراوان هستند و با انتشار کربن صفر یا بسیار کم از نظر اقتصادی جذاب هستند. از سوی دیگر، شرایط سخت محیطی و آب و هوایی مانند تجمع خاک و گرد و غبار بر کارایی منابع و سیستم‌های انرژی تجدیدپذیر تأثیر می‌گذارد. بر این اساس، نیاز به بازرسی خودکار صفحه‌های فتوولتائیک با افزایش تقاضا برای تولید و نصب سیستم‌های جدید انرژی خورشیدی در سراسر جهان حیاتی‌تر می‌شود. در این مطالعه، مجموعه داده جدیدی از تصاویر صفحه‌های غبارآلود و تمیز معرفی شده است. پس از آن، یک معماری شبکه عصبی کانولوشنال جدید جهت تشخیص ولتاژ تولید شده توسط صفحه فتوولتائیک معرفی شده است. در ادامه، پارامترهای برداشت شده از محیط و ولتاژ تخمین زده شده توسط شبکه عصبی پیشنهادی، با استفاده از الگوریتم رگرسیون جنگل تصادفی مورد بررسی قرار گرفته و راندمان صفحه محاسبه شده است. مجموعه فرآیند پیشنهادی به طور خاص با تشخیص تجمع گرد و غبار صفحه‌های فتوولتائیک سروکار دارد. نتایج به دست آمده در این کار به طور تجربی نشان داده‌اند که سیستم پیشنهادی نرخ‌های تشخیص بالایی را تولید می‌کند. روش جدید پیشنهادی منجر به پیاده‌سازی یک تکنیک تمیزکردن خودکار موثرتر و کارآمدتر برای صفحه‌های فتوولتائیک می‌شود.

کلمات کلیدی

بازده الکتریکی، صفحه‌های فتوولتائیک، یادگیری عمیق، رگرسیون، شبکه کانولوشن.

نام نویسنده مسئول: دکتر سید محمد جوادی مقدم

ایمیل نویسنده مسئول: smjavadim@buqaen.ac.ir

تاریخ ارسال مقاله: ۱۴۰۲/۰۶/۲۱

تاریخ(های) اصلاح مقاله: ۱۴۰۲/۰۸/۲۷

تاریخ پذیرش مقاله: ۱۴۰۲/۱۰/۰۹

۱- مقدمه

کاهش منابع سوخت‌های فسیلی، افزایش نگرانی‌های زیست محیطی به خاطر مصرف این سوخت‌ها موجب آن شده که توسعه سامانه‌های تبدیل انرژی‌های تجدیدپذیر، توجه زیادی را در سراسر جهان به خود جلب کند. در بین منابع انرژی تجدیدپذیر، انرژی خورشیدی به دلیل ویژگی‌های خاص آن مانند دسترسی آسان و فراوان، پاک و پایداری بیشتر مورد توجه قرار گرفته است. ظرفیت نیروگاه‌های فتوولتائیک طی چند سال گذشته به طور قابل توجهی در سراسر جهان افزایش یافته است. یک نیروگاه فتوولتائیک، به طور معمول، دارای صدها یا هزاران صفحه فتوولتائیک است که در یک مدار، به صورت سری و موازی، به هم متصل می‌شوند. این صفحه‌ها، اجزای کلیدی در یک نیروگاه فتوولتائیک هستند زیرا بازده خروجی نیروگاه به آنها بستگی دارد [۱].

مطالعات متعددی در مورد عملکرد صفحه‌های فتوولتائیک وجود دارد. اگرچه بازده صفحه‌های فتوولتائیک با پیشرفت‌های اخیر افزایش یافته است، اما عوامل محیطی و طبیعی مانند تجمع خاک، نمک، فضولات پرندگان، برف، و موارد دیگر بر روی سطح آنها وجود دارد که می‌تواند منجر به کاهش بازده تولید توان هر یک از آنها شود [۲]. نیروگاه‌های فتوولتائیک بزرگ، که به نیروگاه‌های مگاواتی معروفند، به زمین‌های عظیم نیاز دارند، بنابراین به طور معمول، در مناطق باز مانند بیابان‌ها و زمین‌های کشاورزی احداث می‌شوند. با توجه به اینکه در این مکان‌ها، فضای اطراف نیروگاه، برای جلوگیری از سایه‌اندازی، خالی است، پیکربندی کلی سطح زمین، به طور عمده، خاک ماسه‌ای است، بنابراین سطح صفحه فتوولتائیک، به طور دائم، در معرض گرد و غبار وجود دارد و به راحتی با گرد و غبار پوشانده می‌شود. از این رو، مطالعه تاثیر انباشت گرد و غبار بر ویژگی‌های عملکردی صفحه‌های فتوولتائیک و بهبود بازده تولید برق آن بسیار مهم است.

آلودگی صفحه فتوولتائیک، به طور معمول، ناشی از انباشت گرد و غبار شامل ترکیبات شن، خاک و سنگ، نخاله‌های ساختمانی، ریزگردهای ناشی از ترافیک خودرو، فضولات پرندگان و همچنین گرده‌های گل‌ها و درختان می‌باشد. گرد و غبار تمایل دارد روی سطح صفحه فتوولتائیک جمع شود. با انباشت گرد و غبار روی سطح شیشه‌ای صفحه‌های فتوولتائیک، تولید انرژی کاهش می‌یابد، زیرا گرد و غبار، مانعی در برابر ورود نور به شیشه و جذب آن توسط سلول‌های فتوولتائیک می‌باشد. افت توان تولیدی به مقدار گرد و غبار، اندازه ذرات و جنس آنها بستگی دارد. گرد و غبار، تولید انرژی صفحه‌های فتوولتائیک را به دو صورت تغییر می‌دهد. ذرات گرد و غبار، نور را پراکنده می‌کنند و میزان تشعشعات رسیده به سطح صفحه را کاهش می‌دهند. علاوه بر این، باعث تشکیل یک لایه غبار ضخیم بر روی صفحه فتوولتائیک می‌شوند. این لایه می‌تواند خواص نوری پانل را تغییر دهد تا بازتاب و جذب نور را افزایش دهد و تولید انرژی را کاهش دهد [۳].

محققین زیادی اثر انباشت گرد و غبار بر کاهش بازده صفحه‌های فتوولتائیک را بررسی کرده‌اند. فان توان خروجی صفحه‌های فتوولتائیک را با شش آلاینده، شامل خاکستر، لاتریت، گرد و غبار سنگ، ماسه، پودر زغال سنگ و سیمان مورد بررسی قرار داده است [۴]. چنانچه اثر تجمع گرد و غبار و بارندگی بر کاهش توان صفحه‌های فتوولتائیک در شرق چین را مورد مطالعه قرار داده است [۵]. ینگیاچن نشان داد انباشت گرد و غبار با غلظت ۱۰ گرم بر متر مربع می‌تواند توان صفحه فتوولتائیک را حدود ۳۴٪ کاهش دهد [۶]. محمود نشان داد که تمیز کردن صفحه‌های فتوولتائیک باعث افزایش میانگین ۳۲.۲۷٪ تولید

برق می‌شود [۷].

بنابراین، یکی از چالش‌های مهم در نیروگاه‌های فتوولتائیک حذف گرد و غبار صفحه‌ها می‌باشد. روش‌های زیادی برای تمیز کردن صفحه‌های فتوولتائیک وجود دارد که از آن جمله، می‌توان به روش‌های دستی، مکانیکی، شیمیایی و الکترواستاتیکی اشاره کرد [۸]. آلاگوز، نقش امواج صوتی سطحی در فرآیند حذف گرد و غبار از سطح صفحه‌های فتوولتائیک را بررسی کرد [۹]. اغلب، روش تمیز کردن در حذف ذرات کوچک گرد و غبار بسیار مؤثر نیست. همچنین، برخی از این روش‌ها به دلیل واکنش با انواع خاصی از ناخالصی‌ها، ممکن است موجب خوردگی صفحه‌های فتوولتائیک شوند از جمله روش‌های امروزی می‌توان به روش توان الکترواستاتیک و الکترواستاتیک [10]، استفاده از یک ربات برای تمیز کردن صفحه‌های فتوولتائیک [11] اشاره کرد. آلوارز و همکاران فرکانس و هزینه تعدادی از روش‌های تمیز کردن را بررسی کردند. این مطالعه روش تمیز کردن را برای انتخاب بهترین استراتژی پیشنهاد کرد که به هزینه، کارایی تجهیزات و سایر پارامترهای سیستم مربوط می‌شود [۱۲].

با توجه به هزینه بالای تمیزکاری، آب و مواد پاک‌کننده مصرفی، تشخیص صفحه‌های آلوده و تمیز کردن آنها، به جای تمیز کردن تمام نیروگاه، می‌تواند نقش مهمی در کاهش هزینه‌های تمیزکاری و مصرف آب و مواد شوینده داشته باشد. علاوه بر این، از آنجاکه، در توجیه اقتصادی نیروگاه‌های فتوولتائیک یکی از بخش‌های مهم در هزینه‌های تولید نیروگاه، هزینه نگهداری می‌باشد، تشخیص صفحه‌های آلوده، یکی از روش‌هایی است که می‌تواند باعث کاهش هزینه تمیزکاری و در نهایت هزینه نگهداری و بهبود توجیه اقتصادی نیروگاه شود.

روش‌های متفاوتی برای تشخیص صفحه‌های آلوده توسط محققین مختلف پیشنهاد شده است. این روش‌ها را می‌توان به دو دسته تقسیم کرد.

دسته اول روش‌هایی هستند که با نصب یک ابزار سنجش، تراکم آلودگی روی سطح صفحه فتوولتائیک را تشخیص می‌دهند. فرناندز سولاس یک روش تحلیلی با استفاده از داده‌های خروجی صفحه‌های فتوولتائیک برای تشخیص صفحه آلوده پیشنهاد کرد [۱۳]. چاماس یک سیستم تشخیص خودکار گرد و غبار را طراحی کرد که در آن با نصب حسگر و یک مدار در خروجی صفحه فتوولتائیک، کاهش تولید ناشی از گرد و غبار را تشخیص می‌دهد [۱۴]. ویلیامز از یک حسگر فتوالکترونیک برای تشخیص آلودگی صفحه فتوولتائیک استفاده کرد. این سیستم مجهز به یک سیستم هشدار بود که پیامک هشدار تمیزکاری را از طریق تلفن همراه ارسال می‌کرد [۱۵].

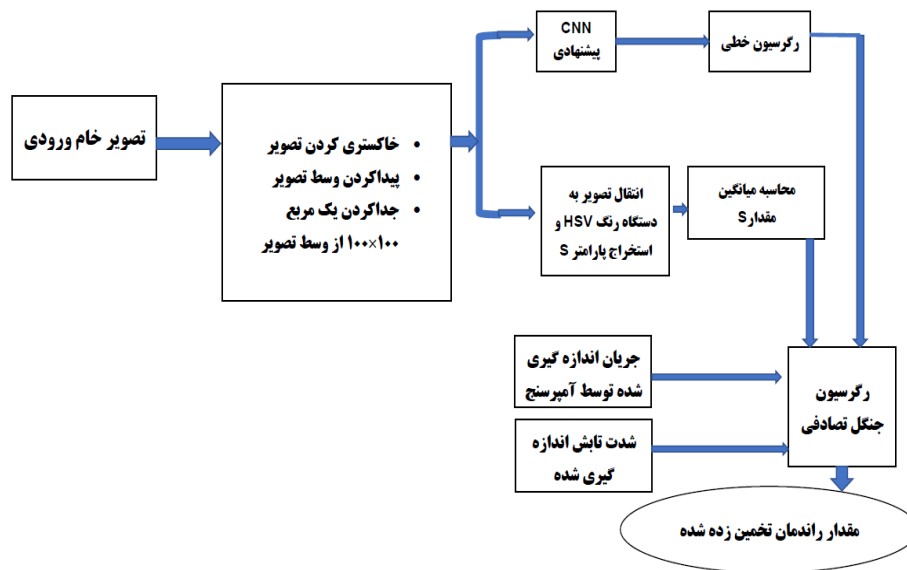
دسته دوم روش‌های مبتنی بر تصویر می‌باشند. فولوانی و همکاران شرایط عادی و معیوب صفحه‌های فتوولتائیک را با استفاده از دوربین حرارتی برای مقایسه عملکرد تجزیه و تحلیل کرد [۱۶]. انلوترک از منبع نور مصنوعی در محیط آزمایشگاهی برای مقایسه خروجی برق برای سه تراکم مختلف انباشت گرد و غبار روی سطح صفحه استفاده کردند [۱۷]. در روش پیشنهادی آنها، از تصاویر صفحه‌های فتوولتائیک به دست آمده توسط دوربین برای سطوح مختلف تجمع گرد و غبار، ویژگی‌های جدیدی بر اساس ماتریس هم‌وقوع سطح خاکستری حاصل می‌شود. سپس، داده‌های به دست آمده با ویژگی‌های جدید بر اساس شبکه‌های عصبی مصنوعی برای تعیین سطح گرد و غبار و تأثیر آن بر عملکرد صفحه‌های فتوولتائیک طبقه‌بندی استفاده می‌شود. دقت بدست آمده در این روش ۹۱/۴۳٪ بود. سکیب یک روش مبتنی بر شبکه عصبی برای پیش بینی تراکم گرد و غبار پیشنهاد کرد. نتایج دقت و مقایسه با روش‌های دیگر در این تحقیق نشان داده نشده است [۱۸]. فان یک روش تشخیص گرد و غبار مبتنی بر شبکه عصبی پس‌مانده^۱ عمیق ارائه کرد [۱۹]. عناصر پس‌مانده در

جدیدی از صفحه‌های کثیف و تمیز با سطح کثیفی مختلف جمع‌آوری شده است. علاوه بر این، با توجه به هزینه بالای تمیزکاری صفحه‌های فتولتائیک، تشخیص دقیق صفحه کثیف برای کاهش هزینه ضروری می‌باشد. لذا در این تحقیق، یک روش تشخیص بازده الکتریکی صفحه‌های فتولتائیک مبتنی بر یادگیری عمیق ارائه شده است. در این روش ولتاژ استفاده شده برای محاسبه بازده الکتریکی نیز با استفاده از یک رگرسیون خطی تخمین زده می‌شود. هدف این پژوهش، ارزیابی عملکرد روش پیشنهادی بر روی مجموعه داده جدید می‌باشد.

۲- مطالب اصلی

۲-۱- مدل پیشنهادی

شکل ۱ مراحل مدل پیشنهادی در تحقیق حاضر را نشان می‌دهد.



شکل ۱- مراحل مدل پیشنهادی

مجموعه تصاویر با سطوح مختلف گرد و غبار روی صفحه‌ها و در شدت تابش‌های مختلف تهیه شده‌اند. به منظور یافتن دامنه اندازه ذرات ریز خاک آزمایش هیدرومتری بکار گرفته شد. در شاخه مکانیک خاک از این آزمایش برای دانه‌بندی بخش ریزدانه خاک استفاده می‌شود [۲۱]. این شیوه مبتنی بر قانون استوکس است که بیان می‌کند سقوط ذرات کروی در محلول متناسب با مجذور قطر اندازه ذرات است. به این منظور ۵۰ گرم از خاک استفاده شده در یک استوانه مدرج به حجم ۱۰۰۰ سی‌سی ریخته شده و با آب مقطر پر می‌گردد. در بازه‌های زمانی مشخص هیدرومتر H1۵۲ برای تعیین قطر ذرات معلق در استوانه مدرج قرار داده می‌شود. با استفاده از داده‌های این آزمایش نمودار دانه بندی ذرات خاک در مقیاس نیمه لگاریتمی قابل ترسیم است.

علاوه بر این، ولتاژ مدار-باز، جریان اتصال کوتاه خروجی و شدت تابش خورشید روی سطح صفحه فتولتائیک و متناظر با هر تصویر مشخص اندازه گیری شد. نمونه‌ای از تصاویر مجموعه داده در شکل ۲ نشان داده شده است.

۲-۳- پیش پردازش تصاویر

شکل ۳ مراحل پیش پردازش تصاویر را نشان می‌دهد. تصاویر ابتدا به صورت خاکستری یک کانال تبدیل شدند و سپس برای کاهش خطای زاویه و فاصله تصویر یک برش مرکزی از آن تهیه گردید و اندازه آن به یک تصویر یک کاناله ۱۰۰x۱۰۰ تغییر کرد.

این مدل به شکل لایه‌های پرش به هم متصل می‌شوند تا ترتیب ماتریس‌های وزن را کاهش دهند و انعطاف‌پذیری شبکه و دقت یادگیری ویژگی را بهبود بخشند. میانگین خطای مطلق در این روش ۳/۶۷٪ و ضریب تعیین R^2 ۷۸/۷٪ گزارش شده است. ابوقاعد یک روش جدید برای تشخیص تجمع خاک و غبار با استفاده از بینایی کامپیوتر ارائه کرد [۲۰]. در این روش، پس از پیش پردازش، ویژگی‌ها با استفاده از ماتریس همزمانی سطح خاکستری از لایه Hue فضای رنگی HSV استخراج می‌شوند. سپس طبقه‌بندی خطی برای جداسازی صفحه‌های تمیز و کثیف اجرا می‌شود. میانگین مقدار تشخیص در این روش ۸۲٪ بوده است.

کمبود مجموعه داده‌های مناسب و متعادل، ساخت مدلی با پارامترهای مناسب را دشوار می‌کند و شکاف تحقیقاتی متمایز برای ارزیابی الگوریتم‌های پیشرفته با مجموعه داده‌های مناسب وجود دارد. در این مقاله مجموعه داده

در شکل ۱، بخش اول مجموعه داده‌های جمع‌آوری شده برای این منظور را توضیح می‌دهد. پس از آن، ساختار مدل پیشنهادی معرفی می‌شود.

۲-۲- تهیه مجموعه داده

تصاویر مجموعه داده در دانشگاه بزرگمهر قائنات در تیرماه ۱۴۰۱ در ساعت ۹ تا ۱۳ با استفاده از دوربین تست^۲ مدل ۸۶۸ جمع‌آوری شده‌اند. جدول ۱ مشخصات صفحه فتولتائیک استفاده شده در تهیه تصاویر را نشان می‌دهد.

جدول ۱- مشخصات فنی صفحه فتولتائیک استفاده شده در تحقیق

مشخصه	مقدار
شرکت سازنده	Trina Solar
نوع سلول	سیلیکون تک- کریستالی
توان بیشینه	۵۰۰ وات
ولتاژ بیشینه	۴۲ ولت
جریان بیشینه	۱۱/۴۲ آمپر
ولتاژ مدار باز	۵۰/۸ ولت
جریان اتصال کوتاه	۱۱/۹۹ آمپر

حسب وات بر متر مربع می‌باشد.

۲-۶- ارزیابی

برای ارزیابی مدل پیشنهادی دو سنجش انجام شده است.

آزمایش اول

هدف این آزمایش، تشخیص مقدار ولتاژ مدار-باز خروجی صفحه فتوولتائیک است. برای بالا بردن دقت کار، ابتدا داده‌ها بر اساس ولتاژ مدار باز خروجی به دو دسته زیر بیست و بالای بیست ولت تقسیم شدند. سپس براساس این دو دسته، طبقه‌بندی انجام شد و معیارهای طبقه‌بندی که در جدول ۲ نشان داده شده مورد بررسی قرار گرفت. در گام بعدی، رگرسیون خطی برای تشخیص مقدار دقیق ولتاژ اتصال کوتاه خروجی پیاده شد و ولتاژ تخمینی برای آزمایش دوم مورد استفاده قرار گرفت.

جدول ۲- مشخصات کلاس‌های طبقه بندی

تعداد داده های زیر بیست ولت	کلاس یک	۱۹۶
تعداد داده های بالای بیست ولت	کلاس دو	۲۳۱


آزمایش دوم

در این آزمایش، از روی چهار پارامتر جدول ۳، مقدار بازده تخمین زده شد. برای محاسبه‌ی پارامتر HSV_Mean، ابتدا تصویرپیش پردازش شده به دستگاه رنگ HSV تبدیل شد. سپس میانگین مقدار اشباع (مقدار S در دستگاه رنگ HSV) محاسبه گردید. این کار برای تمام تصاویر اجرا شد. برای پارامتر ولتاژ نیز از ولتاژ تخمین زده شده آزمایش اول استفاده می‌کنیم.


جدول ۳- پارامترهای پیش بینی

پارامتر	تعریف
Voc	ولتاژ اتصال کوتاه تخمین زده شده
Isc	جریان اتصال کوتاه
R _{solar radiation intensity}	شدت تابش خورشید
HSV_Mean	میانگین مقدار S در دستگاه رنگ HSV

برای پیش‌بینی عددی، از رگرسیون جنگل تصادفی^۵ استفاده شد. جنگل تصادفی یک الگوریتم یادگیری تحت‌نظارت است که از آن هم برای طبقه‌بندی و هم رگرسیون استفاده می‌شود. جنگل تصادفی همزمان با رشد خود، درختان تصادفی بیشتری را به مجموعه اضافه می‌کند. این روش، به جای جست‌وجوی مهم‌ترین ویژگی درحین تقسیم یک گره، بهترین ویژگی را در میان زیر مجموعه‌ای تصادفی از ویژگی‌ها جست‌وجو می‌کند. این عمل، منجر به تنوع گسترده‌ای می‌شود که به طور کلی می‌تواند مدل بهتری را ارائه دهد. بنابراین، در جنگل تصادفی تنها یک زیر مجموعه تصادفی از ویژگی‌ها، توسط الگوریتم تقسیم یک گره در نظر گرفته می‌شود. شکل ۵ مراحل انجام آزمون دوم را نشان می‌دهد.



شکل ۲- نمونه ای از تصاویر مجموعه داده



شکل ۳- مراحل پیش پردازش تصاویر

۲-۴- شبکه پیشنهادی

شکل ۴ معماری و شکل لایه‌های مدل پیشنهادی را نشان می‌دهد. بعد از لایه ورودی، دو لایه کانولوشن دو بعدی به همراه نرمال‌سازی دسته‌ای قرار گرفته است. لایه‌های کانولوشن به ترتیب شامل ۱۶، ۱۶، ۳۲ و ۳۲ فیلتر با اندازه هسته ۳×۳ می‌باشند. در نقاط مختلفی از شبکه از لایه نرمال‌سازی دسته‌ای استفاده شد تا دوره آموزشی را برای پردازش موازی کاهش دهد. همچنین، از لایه ادغام Max Pooling و چهار لایه حذف تصادفی^۴ استفاده گردید. مدل پیشنهادی از relu برای توابع فعال‌سازی در لایه‌های مخفی و Softmax برای لایه خروجی خود استفاده کرد. تعداد پارامترهای شبکه ۸۴۸۳۷۰۷، پارامترهای آموزشی ۸۴۸۳۵۱۵ و پارامترهای غیر آموزشی ۱۹۲ بودند.

۲-۵- بازده الکتریکی

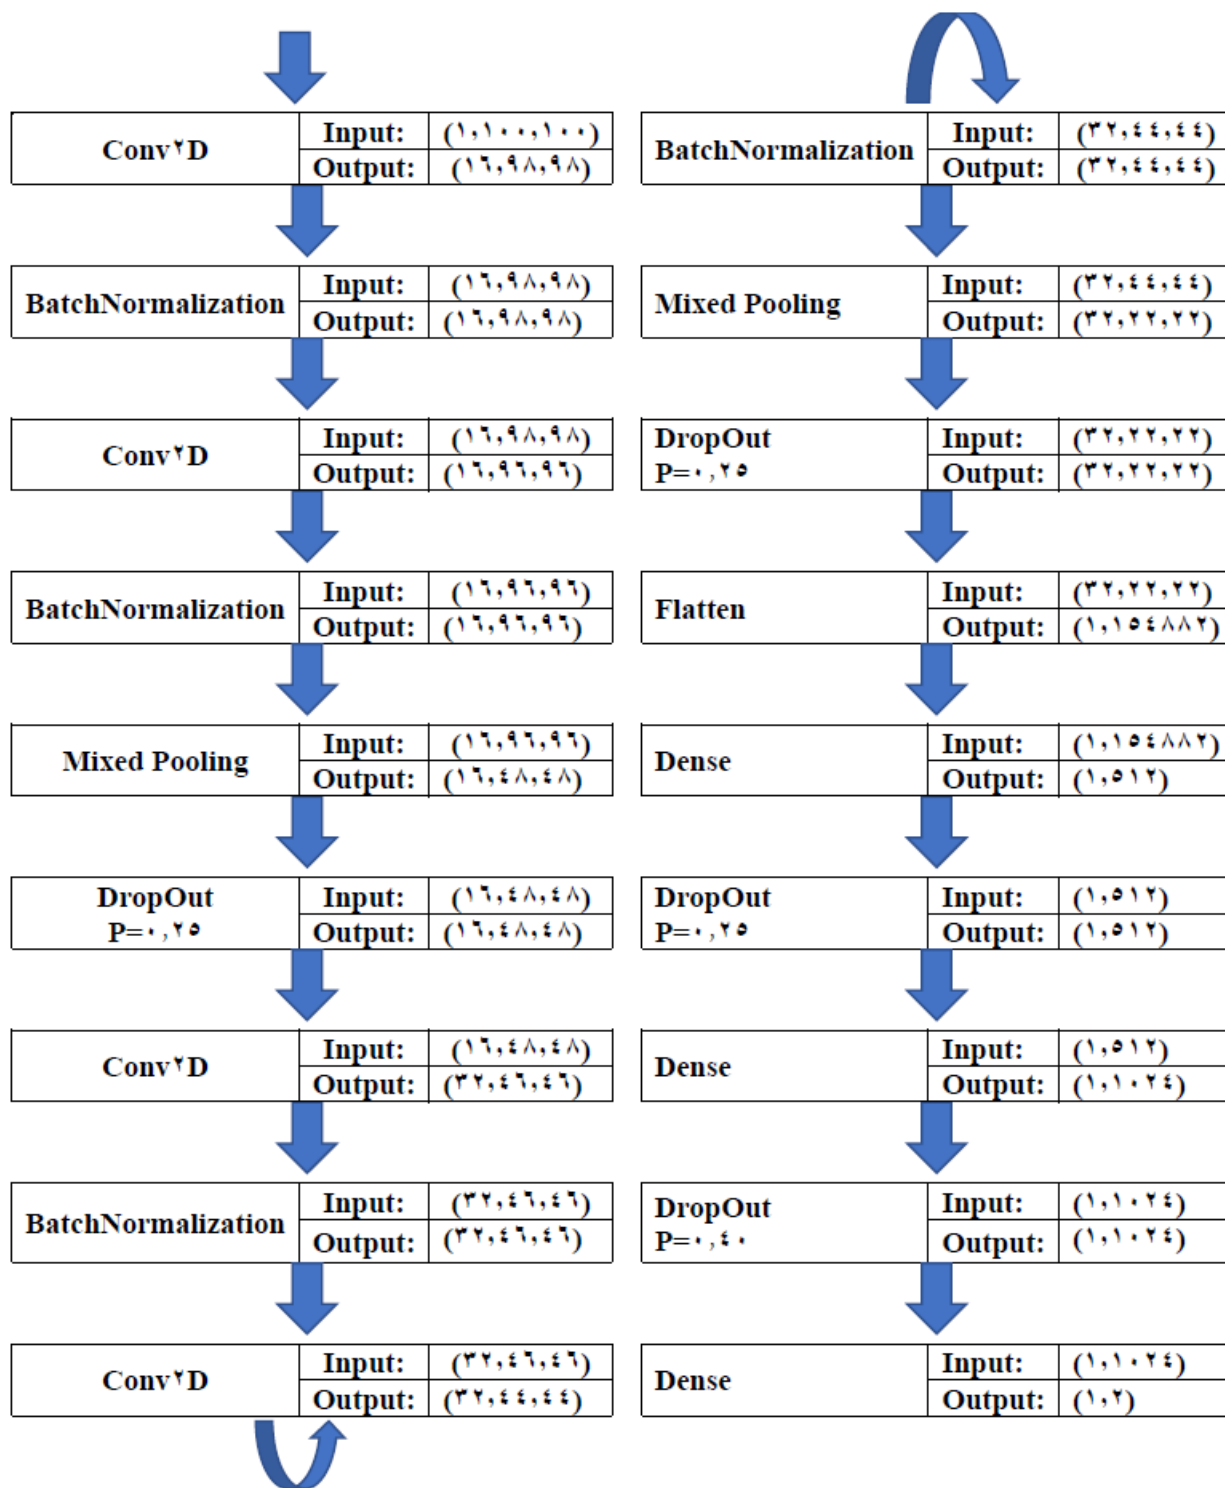
بازده الکتریکی یک صفحه فتوولتائیک براساس سه پارامتر ولتاژ، جریان و شدت تابش بر اساس معادله ۱ محاسبه می‌شود.

$$\eta = \frac{I_{sc} \times V_{oc} \times FF}{A_p \times G} \times 100 \quad (1)$$

در این معادله η بازده الکتریکی صفحه فتوولتائیک، FF ضریب پرشدگی که مقدار آن ۰.۸ در نظر گرفته شد [۲۳، ۲۲]، Voc ولتاژ مدار باز، Isc جریان اتصال کوتاه، A_p مساحت سطح پنل بر حسب متر مربع و G شدت تابش بر

^۵ Random Forest Regression

^۴ Dropout



شکل ۴- ساختار شبکه پیشنهادی

می‌شود، پارامتر تشخیص‌پذیری^{۱۴} است که به معنی نسبتی از موارد منفی است که آزمایش آن‌ها را به درستی به عنوان نمونه منفی تشخیص داده است.

$$Specificity = \frac{TN}{TN + FP} \quad (5)$$

معیار F-Score در واقع ترکیبی از معیارهای دقت و صحت است. معادله ۶ روش محاسبه آن را نشان می‌دهد:

$$F - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

همبستگی متیوز^{۱۵}، پارامتر دیگری است که برای ارزیابی کارایی الگوریتم‌های یادگیری ماشین از آن استفاده می‌شود. این پارامتر میان‌بستگی مقادیر مشاهده شده از کلاس و مقادیر پیش‌بینی شده از آن می‌باشد. معادله ۷ برای محاسبه این معیار استفاده می‌شود:

$$MCC = \frac{TN \times TP - FN \times FP}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (7)$$

ضریب همبستگی پیرسون^{۱۶} ضریب همبستگی پیرسون میان دو متغیر تصادفی برابر با کوواریانس آنها تقسیم بر انحراف معیار آنها تعریف می‌شود. این ضریب بین -۱ و ۱ تغییر می‌کند. اگر $r=1$ باشد، نشان دهنده رابطه مستقیم کامل بین دو متغیر است. رابطه مستقیم یا مثبت نشان می‌دهد که اگر یکی از متغیرها افزایش (کاهش) یابد، دیگری نیز افزایش (کاهش) می‌یابد. معادله ۸ روش محاسبه آن را نشان می‌دهد.

$$\rho_{X,Y} = \frac{cov(X,Y)}{\sigma_X \sigma_Y} \quad (8)$$

در این رابطه cov کواریانس و σ انحراف معیار متغیرها را نشان می‌دهند.

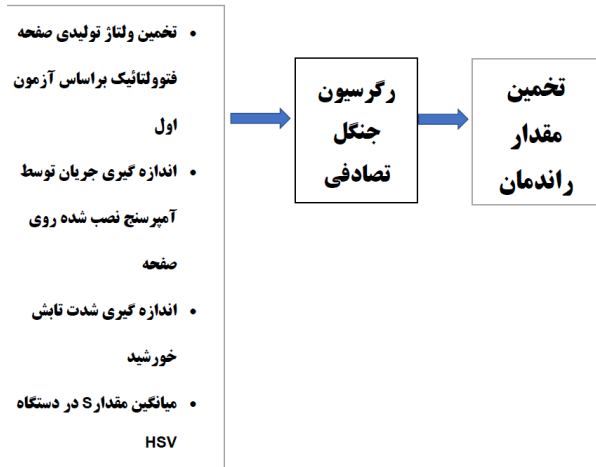
ضریب تعیین که به آن ضریب تشخیص^{۱۷} نیز گفته می‌شود، و تقریباً همه جا با علامت R^2 نمایش داده می‌شود، معروف‌ترین معیار سنجش مطلوبیت برازش مدل است. بنا بر تعریف، ضریب همبستگی می‌بایست بین -۱ و ۱ قرار گیرد. در نتیجه R^2 که توان دوم آن است بین صفر و یک قرار خواهد داشت. اگر این همبستگی زیاد باشد، مدل داده‌ها را خوب برازش کرده است، در حالی که اگر همبستگی پایین (نزدیک به صفر) باشد، مدل برازش خوبی از داده‌ها ارائه نداده است. در حقیقت ضریب تعیین بیانگر نسبت تغییرات توضیح داده شده (ESS) به تغییرات کل (TSS) است:

$$R^2 = \frac{ESS}{TSS} = \frac{TSS - RSS}{TSS} = 1 - \frac{RSS}{TSS} \quad (9)$$

که RSS تغییرات باقیمانده‌ها (جملات خطا) مدل است.

یک معیار اندازه‌گیری خطا به صورت میانگین‌گیری از خطای مطلق^{۱۸} محاسبه می‌شود. در محث خطای‌های مدل، این میانگین تفاوت بین مقدار واقعی و مقدار پیش‌بینی شده بر روی تمام نمونه‌های آموزش را نشان می‌دهد.

ورودی‌ها



شکل ۵- مراحل آزمون دوم

معیارهای ارزیابی

مقادیر طبقه بندی می‌توانند در یکی از دسته‌های زیر قرار گیرند: مثبت صحیح^۶: الگوریتم نمونه را در دسته مثبت طبقه‌بندی کرده و نمونه هم مثبت است
مثبت کاذب^۷: الگوریتم نمونه را در دسته مثبت طبقه‌بندی کرده اما نمونه منفی است
منفی صحیح^۸: الگوریتم نمونه را در دسته منفی طبقه‌بندی کرده و نمونه هم منفی است
منفی کاذب^۹: الگوریتم نمونه را در دسته منفی طبقه‌بندی کرده اما نمونه مثبت است
صحت^{۱۰} مدل را می‌توانیم با نسبت زیر محاسبه کنیم:

$$Accuracy = \frac{TP + TN}{TN + FN + TP + FP} \quad (2)$$

منظور از دقت^{۱۱}، مقدار نمونه‌هایی است که الگوریتم کلاس آن‌ها را به درستی پیش‌بینی کرده و آن‌ها را در دسته مثبت طبقه‌بندی کرده است. بنابراین:

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

یکی دیگر از معیارهای ارزیابی عملکرد مدل، معیار پوشش^{۱۲} یا حساسیت^{۱۳} است. این معیار می‌تواند نسبت تعداد نمونه‌هایی که الگوریتم در دسته مثبت طبقه‌بندی کرده را نسبت به تعداد کل نمونه‌های مثبت نشان دهد.

$$Sensitivity = \frac{TP}{TP + FN} \quad (4)$$

از متداول‌ترین پارامترها که به طور معمول، در کنار حساسیت بررسی


- Sensitivity^{۱۳}
- Specificity^{۱۴}
- Matthews correlation coefficient (MCC)^{۱۵}
- Pearson correlation coefficient^{۱۶}
- Coefficient of Determination^{۱۷}
- Mean Absolute Error (MAE)^{۱۸}

- TP^۶
- FP^۷
- TN^۸
- FN^۹
- Accuracy^{۱۰}
- Precision^{۱۱}
- Recall^{۱۲}

ماتریس اغتشاش^{۲۳} آزمایش اول در جدول ۴ و شکل ۷ نشان داده شده است. همچنین جدول ۵ شامل مقادیر پارامترهای ارزیابی حاصل از انجام آزمایش اول می‌باشد.

جدول ۴- ماتریس اغتشاش

		برچسب شناسایی شده	
برچسب واقعی		کلاس ۱	کلاس ۲
	کلاس ۱	۱۹۲	۴
	کلاس ۲	۶	۲۲۵



شکل ۷- ماتریس اغتشاش

جدول ۵- نتایج طبقه بندی داده ها بر اساس دو کلاس زیر بیست ولت و بالای بیست ولت

Sensitivity	97.96
Specificity	97.40
Precision	96.97
Negative Predictive Value	98.25
False Positive Rate	2.60
False Discovery Rate	3.03

مثلا برای n نمونه آزمایش، برای هر مقدار واقعی y و مقدار پیش‌بینی شده y'، این معیار براساس معادله ۱۰ محاسبه می‌شود:

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - y'_i| \quad (10)$$

میانگین مربعات خطا^{۱۹} یکی از پرکاربردترین معیارها است که هم در آموزش مدل‌ها و هم در مقایسه مدل‌ها استفاده می‌شود. معادله ۱۱ میانگین مربعات خطا را محاسبه می‌کند.

$$MSE(Y, Y') = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (11)$$

میانگین مربعات خطای لگاریتمی^{۲۰} تفاوت نسبی بین مقادیر واقعی و پیش‌بینی شده تغییر شکل یافته است. این معیار با معادله ۱۲ محاسبه می‌شود.

$$L(y, y') = \frac{1}{N} \sum_{i=0}^N (\log(y_i + 1) - \log(y'_i + 1))^2 \quad (12)$$

خطای مطلق میانه^{۲۱} نسبت به موارد پرت حساس‌تر است و بیانگر تفاوت‌های مطلق بین مقدار واقعی و پیش‌بینی شده می‌باشد. معادله ۱۳ روش محاسبه این خطا را نشان می‌دهد.

$$Median Absolute Error = median|y_{i,pred} - y_{i,true}| \quad (13)$$

که در آن y_{i,pred} مقادیر پیش‌بینی شده و y_{i,true} مقادیر واقعی برای همه نمونه‌های i هستند.

واریانس تفضیلی رگرسیون^{۲۲} عبارت از رگرسیون خطی بر اساس واریانس تفضیلی می‌باشد. این معیار با استفاده از معادله ۱۴ محاسبه می‌شود.

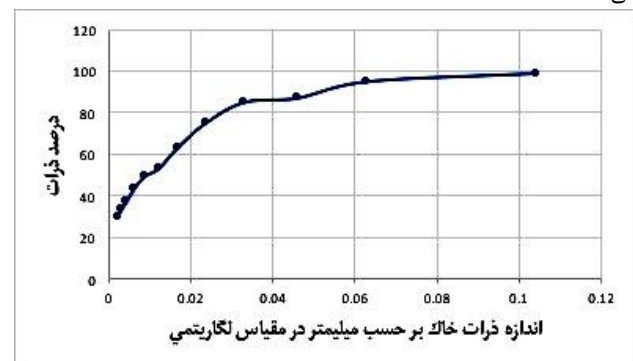
$$S(y, y') = 1 - \frac{Var\{y - y'\}}{Var\{y\}} \quad (14)$$

که در آن Var نشان دهنده واریانس می‌باشد.

۲-۷- نتایج

شکل ۶ نمودار اندازه ذرات استفاده شده در تهیه مجموعه داده را نشان

می‌دهد.



شکل ۶- نمودار اندازه ذرات

^{۲۳} Explained variance Regression score
Confusion Matrix

^{۱۹} Mean Squared Error (MSE)
^{۲۰} Mean squared logarithmic error
^{۲۱} Median absolute error

دستگاه از روی پارامترهای تعیین شده در جدول ۲ است. برای این آزمون، از روش رگرسیون جنگل تصادفی استفاده شده است و نتایج آن در جدول ۶ نشان داده شده است. همانطور که در این نتایج مشاهده می‌شود، مقدار همبستگی پیرسون ۰/۹۹۸ است که بسیار نزدیک به یک است. این نزدیکی مقدار، نشان دهنده‌ی نزدیک بودن خطی تغییر مقدار راندمان و پارامترهای جدول ۲ است و این خطی بودن، به معنای ساده‌بودن سیستم است. دقت روش نیز از طریق مقدار خطای مطلق میانه قابل بررسی است که مقدارش برابر ۱/۱۴۷ است. خطای شناسایی در این آزمون یک درصد است که مقداری معقول است.

۳- نتیجه گیری

عوامل محیطی و طبیعی مانند رسوب خاک، نمک، فصولات پرنندگان، برف و موارد دیگر باعث کاهش انرژی تولید شده توسط صفحه‌های فتوولتائیک هستند. مقاله حاضر یک روش جدید برای تشخیص خاک و غبار با استفاده از یادگیری عمیق ارائه می‌کند. با توجه به نبود یک مجموعه داده مناسب در این مقاله ابتدا تصاویری با سطوح کثیفی مختلف تهیه شد. سپس از این مجموعه داده برای ارزیابی ساختار پیشنهادی در دو آزمون استفاده شد. در آزمون اول، تصاویر به دو مجموعه تمیز و کثیف طبقه‌بندی شدند. در آزمون دوم، از رگرسیون برای تشخیص صفحه کثیف استفاده شد. ابتدا تصویر به دستگاه رنگ HSV تبدیل شد. سپس، ناحیه‌ی در برگیرنده‌ی صفحه‌ی فتوولتائیک مشخص شده، و در نهایت، میانگین مقدار اشباع محاسبه گردید. برای پیش بینی عددی، از رگرسیون جنگل تصادفی استفاده شد. مقدار همبستگی پیرسون ۰/۹۹۸ بود که بسیار نزدیک به یک است. خطای مطلق میانه برابر ۱/۱۴۷ بود که نشان می‌دهد روش پیشنهادی نرخ تشخیص بالایی بر روی تصاویر آزمایش شده می‌دهد.

مراجع

- [۱] محمدویسی، عباس، حاتمی، علیرضا، «ارائه چارچوبی برای مدیریت انرژی خانه هوشمند: برنامه‌ریزی بهینه تجهیزات خانگی و برنامه‌ریزی بهینه بهره‌برداری از منابع انرژی تجدیدپذیر»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۵، شماره ۱، صفحات 53-66، ۱۳۹۴.
- [۲] رضا شریعتی‌نسب، بهزاد کرمانی کوشه، حمیدرضا نجفی، «طراحی حفاظت نیروگاه‌های خورشیدی در مقابل ضربات صاعقه با استفاده از میله‌های صاعقه‌گیر»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۸، شماره ۱، صفحات ۱۳۹۴، 53-66.
- [3] G. M. Dantas, O. L. C. Mendes, S. M. Maia, and A. R. de Alexandria, "Dust detection in solar panel using image processing techniques: A review," Research, Society and Development, vol. 9, no. 8, pp. 321985107-321985107, 2020.
- [4] S. Fan, Y. Wang, S. Cao, T. Sun, and P. Liu, "A novel method for analyzing the effect of dust accumulation on energy efficiency loss in photovoltaic (PV) system," Energy, vol. 234, pp. 121112, 2021.
- [5] J. Chen, G. Pan, J. Ouyang, J. Ma, L. Fu, and L. Zhang, "Study on impacts of dust accumulation and rainfall on PV power reduction in East China," Energy, vol. 194, pp. 116915, 2020.
- [6] Y. Chen et al., "Experimental study on the effect of dust deposition on photovoltaic panels," Energy Procedia, vol. 158, pp. 483-489, 2019.
- [7] M. Hammoud, B. Shokr, A. Assi, J. Hallal, and P. Khoury, "Effect of dust cleaning on the enhancement of the power generation of a coastal PV-power plant at Zahrani Lebanon," Solar Energy, vol. 184, pp. 195-201, 2019.
- [8] H. A. Kazem, M. T. Chaichan, A. H. Al-Waeli, and K. Sopian, "A review of dust accumulation and cleaning methods for solar photovoltaic systems," Journal of Cleaner Production, vol. 276, pp. 123187, 2020.

False Negative Rate	2.04
Accuracy	97.66
F1 Score	97.46
Matthews Correlation Coefficient	95.29

جدول ۶ نتایج ارزیابی در آزمایش دوم را نشان می‌دهد.

جدول ۶- نتایج معیارهای ارزیابی حاصل از انجام آزمایش دوم

مقدار	معیار
۰/۹۹۸	همبستگی پیرسون
۰/۸۵۸	ضریب تعیین
۱/۱۴۷	میانگین خطای مطلق
۴۶۴/۹۶۵	میانگین مربعات خطا
۰/۰۰۱	میانگین مربعات خطای لگاریتمی
۰/۰۶۹	خطای مطلق میانه
۴۴۵/۵۶۷	خطای ماکسیمم
۰/۸۵۸	واریانس تفضیلی رگرسیون

۲-۸- بحث

همانطور که در قسمت قبل بیان شد، بر روی داده‌ها دو آزمایش انجام شد. آزمایش اول، با هدف تشخیص ولتاژ مدار باز تولیدی توسط صفحه‌های فتوولتائیک، از روی مقدار شدت تابش دریافت شده توسط صفحه، اجرا شده است. نتایج این تشخیص، که از نوع مسائل طبقه‌بندی است، در جدول ۵ نمایش داده شده است. معماری شبکه‌ی عصبی پیشنهادی برای این آزمایش در شکل ۵ نمایش داده شده است. همانطور که دیده می‌شود، اختلاف بین نتایج، حداکثر سه درصد است که نشان دهنده‌ی آنتروپی پایین بین نتایج است و قدرت شبکه برای تشخیص را نشان می‌دهد. از نظر ماتریس اغتشاش که در جدول ۴، نشان داده شده است، فقط ده داده اشتباه شناسایی شده است. دقت را می‌توان تابعی از انحراف معیار داده‌ها به حساب آورد. هرچه انحراف معیار داده‌ها کمتر باشد، سیستم دقیق‌تر است. در این آزمایش مقدار دقت، ۹۶/۹۷ به دست آمده که نشان دهنده‌ی بسیار پایین بودن انحراف معیار داده‌ها است. توانایی آزمایش‌ها در جدا کردن یا تشخیص صحیح کلاس داده‌ها را می‌توان به وسیله‌ی دو معیار حساسیت و ویژگی تشخیص‌پذیری بیان کرد. بالا بودن این مقادیر به معنی توانایی بالای شبکه‌ی پیشنهادی در تشخیص است. کسب این اعداد در معیارها، نشان‌دهنده‌ی قدرت بالای شبکه در تحلیل داده‌ها و تشخیص درست است. آزمایش دوم، از نوع رگرسیون است و هدف آن، پیش‌بینی مقدار راندمان

- International Students' Conference on Electrical, Electronics and Computer Science (SCEECS), IEEE, pp. 1-5, 2020.
- [17] M. Unluturk, A. A. Kulaksiz, and A. Unluturk, "Image Processing-based Assessment of Dust Accumulation on Photovoltaic Modules," in 2019 1st Global Power, Energy and Communication Conference (GPECOM), IEEE, pp. 308-311, 2019.
- [18] D. Saquib, M. N. Nasser, and S. Ramaswamy, "Image Processing Based Dust Detection and prediction of Power using ANN in PV systems," Third International Conference on Smart Systems and Inventive Technology (ICSSIT), IEEE, pp. 1286-1292, 2020.
- [19] S. Fan, Y. Wang, S. Cao, B. Zhao, T. Sun, and P. Liu, "A deep residual neural network identification method for uneven dust accumulation on photovoltaic (PV) panels," *Energy*, vol. 239, pp. 122302, 2022.
- [20] K. A. Abuqaad and A. Ferrah, "A novel technique for detecting and monitoring dust and soil on solar photovoltaic panel," *Advances in Science and Engineering Technology International Conferences (ASET)*, IEEE, pp. 1-6, 2020.
- [21] B. M. Das, *Principles of geotechnical engineering*. Cengage learning Publications, 2021.
- [22] Castaner, L. and Silvester, S, "Modeling photovoltaic Systems Using PSpice". John Willy and Sons Publications, 2002.
- [23] Mortezapour, H., GHobadian, B., Khoshtaghaza, MH and Minaei, S. Performance analysis of a two-way hybrid photovoltaic/thermal solar, *Journal of Agricultural Science and Technology*. Vol. 14, pp. 767-780, 2012.
- [9] S. Alagoz and Y. Apak, "Removal of spoiling materials from solar panel surfaces by applying surface acoustic waves," *Journal of Cleaner Production*, vol. 253, pp. 119992, 2020.
- [10] Calle, Carlos I., et al. "Dust particle removal by electrostatic and dielectrophoretic forces with applications to NASA exploration missions." *Proc. ESA Annual Meeting on Electrostatics*, vol. 01, pp. 1-14, 2008.
- [11] Anderson, Mark, et al. "Robotic device for cleaning photovoltaic panel arrays." *Mobile robotics: Solutions and challenges Publications*. pp. 367-377, 2010..
- [12] D. L. Alvarez, A. S. Al-Sumaiti, and S. R. Rivera, "Estimation of an optimal PV panel cleaning strategy based on both annual radiation profile and module degradation," *IEEE Access*, vol. 8, pp. 63832-63839, 2020.
- [13] Á. Fernández-Solas, J. Montes-Romero, L. Micheli, F. Almonacid, and E. F. Fernández, "Estimation of soiling losses in photovoltaic modules of different technologies through analytical methods," *Energy*, vol. 244, pp. 123173, 2022.
- [14] K. Tsamaase, T. Ramasesane, I. Zibani, E. Matlotse, and K. Motshidisi, "Automated dust detection and cleaning system of PV module," *IOSR J. Electr. Electron. Eng.*, vol. 12, pp. 93-98, 2017.
- [15] C. Williams and S. Bryan, "Dirt sensing on PV modules with automated cleaning request.", 15th LACCEI International Multi-Conference for Engineering, Education, and Technology. pp.19-21, 2017.
- [16] U. K. Phoolwani, T. Sharma, A. Singh, and S. K. Gawre, "IoT based solar panel analysis using thermal imaging," in 2020 IEEE