



پیش‌بینی کوتاه مدت توان فتوولتائیک در نیروگاه خورشیدی به کمک روش‌های یادگیری عمیق

¹ آزاده سلطانی^{*}، ² حمید فدیشه‌ای

¹ و ² - استادیار، گروه مهندسی کامپیوتر، دانشگاه بجنورد، بجنورد، ایران

* بجنورد، کدپستی 9417733841، a.soltani@ub.ac.ir

چکیده

امروزه افزایش روزافزون مصرف انرژی در جهان، محدود بودن سوخت‌های فسیلی و بالابودن میزان آلاینده‌ها، استفاده از انرژی‌های نو و تجدید پذیر همانند انرژی خورشیدی و باد را مورد توجه همگان قرار داده است. انرژی خورشیدی یکی از این انرژی‌ها است که مزایای متعددی از جمله نداشتن آلودگی‌های صوتی و زیست محیطی و رایگان بودن انرژی اولیه دارد. با این وجود، میزان توان تولیدی فتوولتائیک در نیروگاه‌ها به علت وابسته بودن به شرایط مختلف از جمله وضعیت آب و هوایی قابل کنترل نیست. این در حالیست که به منظور فراهم آوردن انرژی الکتریکی با کیفیت بالا برای مصرف‌کنندگان نهایی و بهبود قابلیت اطمینان سیستم، نیازمند پیش‌بینی دقیق آن هستیم. در این تحقیق سه مدل برای پیش‌بینی کوتاه مدت توان خروجی یک نیروگاه پیشنهاد شده که مبتنی بر شبکه عصبی عمیق بوده و از نظر نوع ورودی‌ها و ساختار شبکه با هم متفاوت هستند. مدل‌های پیشنهادی در ساختارشان از شبکه حافظه کوتاه مدت طولانی (LSTM) استفاده کرده و از توانهای خروجی قبلی و پارامترهای آب و هوایی به عنوان ورودی بهره برده‌اند. آزمایش‌های انجام شده نشان می‌دهد، استفاده از ورودی‌هایی مبتنی بر شرایط آب و هوایی، در کنار توان‌های خروجی قبلی، منجر به افزایش دقت پیش‌بینی می‌شود. همچنین استفاده از ساختارهای پیچیده‌تر در شبکه، به بهبود کارایی کمک می‌کند.

کلیدواژگان: انرژی خورشیدی، پیش‌بینی توان فتوولتائیک، یادگیری عمیق، حافظه کوتاه مدت ماندگار

Short-Term Photovoltaic Power Forecasting in a Solar Power Plant based on Deep Learning Methods

Azadeh Soltani^{1*}, Hamid Fadishei²

^{1, 2}-Assistant Professor, Department of Computer Engineering, University of Bojnord, Bojnord, Iran

* P.O.B. 9417733841 Bojnord, Iran, a.soltani@ub.ac.ir

Received: 17 December 2022 Accepted: 10 October 2023

Abstract

Nowadays, the rapidly growing energy consumption in the world along with the shortage of fossil fuels and their high environmental pollution has led to increased attention to renewable energies such as solar and wind energies. Among these, solar energy has many advantages such as no ecological and noise pollution and free use. However, photovoltaic power plant output, due to its dependency on solar irradiance and other weather conditions, has uncontrollable uncertainty. Therefore, for providing high-quality electric energy for end-consumers and enhancing the reliability of the system, photovoltaic power output needs to be predicted accurately. The aim of this paper is to address this issue by proposing three short-term photovoltaic power-forecasting models based on deep-learning neural networks, which differ in terms of input types and network structures. The proposed models use long short-term memory (LSTM) in their structures and historical power outputs and weather conditions as their inputs to forecast one-hour-ahead PV power.

Conducted experiments show that employing weather conditions, in addition to the historical output powers, increases the prediction accuracy. Moreover, utilizing more complicated network structures leads to performance improvements.

Keywords: Solar energy, Photovoltaic power forecasting, Deep learning, Long short-term memory

خورشیدی ایران در سال ۱۳۸۴ افتتاح شد. این نیروگاه ۳۰ کیلو وات، شامل ۶۸۴ پنل خورشیدی ۴۵ وات است. از آن زمان نیروگاه‌های متعددی به شبکه برق کشور اضافه شده است. نیروگاه کوشک یزد چهارمین نیروگاه خورشیدی احداث شده در کشور با ظرفیت ۱۰ مگاوات است که در مهرماه ۱۴۰۰ به بهره برداری رسیده است و در سال نخست ۱۹ میلیون و ۵۰۰ هزار کیلو وات ساعت برق تولید خواهد کرد. در این تحقیق، سه مدل مبتنی بر شبکه عصبی عمیق برای پیش‌بینی توان کوتاه مدت خروجی در نیروگاه کوشک یزد ارائه شده است.

ساختار ادامه این مقاله به این شکل است: ابتدا در فصل ۲، مروری بر کارهای انجام شده قبلی در این حوزه خواهیم داشت. مدل پیشنهادی در فصل ۳ توضیح داده می‌شود. نتایج آزمایش‌ها و بررسی‌ها در فصل ۴ بررسی می‌شود و در نهایت فصل ۵ شامل نتیجه‌گیری است.

۲- مروری بر کارهای پیشین

امروزه در دسترس بودن داده‌های زیاد سبب شده نحوه بسیاری از تصمیم‌گیری‌ها در صنعت تغییر کند. این کاربرد در مدل‌های پیچیده که وابسته به پارامترهای متعددی هستند بسیار کمک کننده است. در حقیقت تکنیک‌های داده کاوی کمک می‌کنند تا بدون نیاز به درگیر شدن با جزئیات داخلی مدل‌ها، بر اساس ورودی‌های مسئله و داده‌های جمع آوری شده، خروجی آن را پیش‌بینی کرد. در حال حاضر، با توجه به بحران انرژی در جهان، اهمیت استفاده از سیستم‌های خورشیدی فتوولتاییک بر کسی پوشیده نیست. همانطور که در بخش قبل بیان شد، به منظور افزایش استفاده از توان فتوولتاییک خورشیدی و مدیریت بهتر ادغام سیستم‌های تولید برق خورشیدی در شبکه برق، نیاز به پیش‌بینی توان خروجی این سیستم‌ها در اوقات مختلف زمانی و مکانی است. به طور مثال، تخمین حدودی توان تولیدی، به کمپانی‌های تولید برق کمک میکند در واحدهای ترکیبی تولید برق، کنترل‌ری ایجاد کنند تا به طور خودکار بین سیستم‌های مختلف تولید برق موجود سوییچ کنند. با توجه به اهمیت بالای این موضوع، در حال حاضر تحقیقات گسترده‌ای بر روی این موضوع انجام شده است که به سه گروه پیش‌بینی بلند مدت (پیش‌بینی یک ماهه یا یک ساله)، میان مدت (زمانی بین یک هفته تا یک ماه را در نظر می‌گیرد) و کوتاه مدت (به بازه زمانی کمتر از یک هفته اشاره دارد) تقسیم می‌شوند [۵]. در این بین پیش‌بینی‌های بلند مدت و میان مدت بیشتر برای برنامه ریزی‌ها و تصمیم‌گیری‌های آینده کاربرد دارند؛ به طور مثال برای کنترل ناپایداری ولتاژ و فرکانس بار بعدی و یا جهت برنامه‌ریزی انتقال برای کاهش نیاز به ذخیره ثانویه. همچنین، پیش‌بینی کوتاه مدت می‌تواند برای پیش‌بینی رمپ‌های توان و نوسانات ولتاژ و همچنین برای کنترل بهتر عملیات در بازار بلادرنگ و مدیریت دیسپاچینگ استفاده شده و قابلیت اعتماد سیستم برق را افزایش دهد [۶].

روش‌های ارائه شده برای پیش‌بینی تولید برق فتوولتاییک را می‌توان به دو دسته کلی تقسیم کرد: (۱) روش‌های قطعی: این دسته از روش‌ها از مدل‌های مبتنی بر فیزیک استفاده می‌کنند و نیازمند اطلاع از جزئیات کامل

۱- مقدمه

امروزه تقاضای انرژی در سراسر جهان بالاتر از هر زمانی در گذشته است و این در حالیست که نفت و سایر منابع فسیلی در حال کمیاب شدن هستند. همچنین پیامدهای زیست‌محیطی سوخت‌های فسیلی مانند گرمایش جهانی و اثرات گلخانه‌ای یک چالش بزرگ است. در این شرایط انرژی‌های پاک، بهترین راه‌حل برای پاسخگویی به این مشکلات هستند. این انرژی‌ها که شامل انرژی‌های تجدید پذیر (از جمله انرژی خورشیدی و بادی) می‌باشند منبع سوخت رایگان را برای بازار جهانی فراهم می‌کنند. در این بین انرژی خورشیدی در راس سرمایه گذاری جهانی قرار دارد [۱]. سیستم‌های خورشیدی فتوولتاییک دارای مزایای متعددی از جمله نداشتن آلودگی‌های زیست محیطی، کم بودن هزینه‌های تعمیر و نگهداری، رایگان بودن انرژی اولیه و همچنین نداشتن آلودگی صوتی می‌باشد.

علی‌رغم تمام مزایایی که انرژی خورشیدی دارد، ادغام فتوولتاییک (PV) خورشیدی در شبکه‌های برق دارای مشکلات متعددی، از جمله غیرقابل پیش‌بینی بودن میزان توان خروجی و وجود گریدهای زیرساختی ضعیف است [۱]. میزان توان خروجی فتوولتاییک بسیار نامطمئن است زیرا به فاکتورهای آب و هوایی متعددی از جمله میزان دما، باد، پوشش ابر و یا رطوبت هوا وابسته است [۲]. این موارد سبب بروز ناپایداری در سیستم و مشکل شدن مدیریت سیستم‌های برق می‌شود [۳]. بنابراین پیش‌بینی درست توان تولید شده، می‌تواند به کنترل تغییر پذیری تولید و ادغام کاراتر این تکنولوژی با شبکه برق موجود کمک کند [۴]. پیش‌بینی پذیر بودن توان خروجی یک نیروگاه، علاوه بر اینکه باعث افزایش قابلیت اعتماد سیستم‌های تولید برق می‌شود، می‌تواند در تعمیر و نگهداری واحدهای نیروگاه نیز کمک کننده باشد. در صورتیکه به پیش‌بینی درستی از تولید دست یابیم، سیستم می‌تواند با مقایسه توان خروجی واقعی و توان پیش‌بینی شده، خرابی در سیستم را به طور خودکار تشخیص دهد همچنین اگر در کنار این سیستم پیش‌بینی کننده، سیستم پیش‌بینی و تشخیص خودکار پنل معیوب هم پیاده سازی شود می‌تواند سبب سرعت بخشیدن به تشخیص خرابی و رفع عیب در سیستم گردد که به طور حتم منافع اقتصادی بالایی به همراه خواهد داشت. با توجه به اهمیت بالای توجه به انرژی‌های پاک و خصوصاً انرژی خورشیدی، تحقیقات گسترده‌ای در زمینه پیش‌بینی توان تولیدی سیستم‌های فتوولتاییک انجام شده است که از روش‌های داده کاوی بهره برده‌اند. این روش‌ها کمک می‌کنند که بتوان بر اساس پیش‌بینی‌های مدل، برنامه ریزی‌های زمانی و مکانی برای شبکه برق انجام داد.

کشور ایران در میان مدارهای ۲۵ تا ۴۰ درجه عرض شمالی قرار گرفته است و در آن به طور میانگین سالیانه بیش از ۲۸۰ روز آفتابی گزارش شده است که بسیار قابل توجه بوده و بالاتر از میانگین جهانی است. استفاده از پنل‌های خورشیدی، قدمتی حدوداً ۳۰ ساله در ایران دارد. اولین نیروگاه

1. Photovoltaic

دایری و همکارانش با استفاده از یک روش یادگیری عمیق مبتنی بر خود رمزنگار متغیر² پیش‌بینی کوتاه مدت داشته‌اند [12]. دلیل استفاده از این روش، کارایی مناسب آن در مدل سازی سری‌های زمانی و تخمین‌های غیر خطی است. این مدلها برای استخراج خودکار اطلاعات از داده‌ها به شیوه‌ای بدون نظارت کارآمد هستند و یکی از ویژگی‌های مطلوبشان، توانایی آن‌ها در کاهش ابعاد ورودی است. برای ایجاد داده‌های آموزشی، توانهای برق تولید شده به صورت یک سری زمانی در نظر گرفته می‌شود. سپس دنباله زمانی به توالی‌هایی تقسیم می‌شود که هر توالی یک نمونه از داده‌های آموزشی را تشکیل می‌دهد. در هر نمونه آموزشی l توان تولیدی پشت سر هم به عنوان ورودی و توان تولیدی لحظه بعد به عنوان خروجی در نظر گرفته می‌شود. پارامتر l در این تحقیق 6 در نظر گرفته شده است.

در [5] از یک روش ترکیبی، مبتنی بر حافظه طولانی کوتاه-مدت (LSTM) و تجزیه بسته موجک (WPD³) برای پیش‌بینی کوتاه مدت استفاده کرده‌اند. در این مدل، ابتدا به کمک WPD سری اصلی به چهار زیر سری تقسیم شده و سپس چهار LSTM روی هر زیر سری آموزش داده می‌شود. در نهایت به کمک ترکیب خطی وزن‌دار چهار خروجی، نتیجه نهایی تولید می‌شود.

لی و همکارانش یک روش مبتنی بر یادگیری عمیق ارائه کرده‌اند که از ترکیب LSTM و CNN⁴ استفاده کرده‌اند [3]. در این مدل شبکه LSTM وظیفه دارد اطلاعات زمانی در آخرین داده‌ها را برای پیش‌بینی بهتر در نظر بگیرد. برای پیش‌بینی توان روز d در لحظه $m + 1$ (p_d^{m+1})، ورودی شبکه LSTM، F توان تولید شده قبلی خواهد بود به طور دقیق‌تر ورودی LSTM به صورت $X_m = [p_d^m, p_d^{m-1}, \dots, p_d^{m-F}]$ است. همچنین CNN از توان‌های تولید شده در لحظه $m + 1$ در k روز قبل برای پیش‌بینی بهره می‌برد. بنابراین بردار $X_d \in R^k$ ایجاد شده و سپس $X_d = [p_d^{m+1}, p_d^{m+1-k}, \dots, p_d^{m+1-k}]$ به ماتریس $X_c \in R^{H \times W}$ تغییر شکل داده می‌شود و به عنوان ورودی به CNN فرستاده می‌شود. در نهایت خروجی کل مدل، میانگین وزن‌دار خروجی دو مدل خواهد بود.

آگوا و همکاران تاثیر عوامل محیطی مختلف از جمله پیش‌بینی‌های آب و هوایی را بر صحت پیش‌بینی توان خروجی بررسی کردند و نشان دادند برای پیش‌بینی‌های بازه زمانی کمتر از 6 ساعت، پیش‌بینی‌های عددی آب و هوایی تاثیری ندارد ولی برای بازه‌های بزرگتر مفید است [13]. در [14] از ترکیب CNN و LSTM برای پیش‌بینی توان خروجی استفاده شده است. ونگ و همکارانش [15] سه مدل LSTM، CNN، و ترکیب این دو را برای پیش‌بینی توان فتوولتائیک استفاده کرده‌اند. در این تحقیق، تنها دنباله‌ای از توان‌های خروجی قبلی به عنوان ورودی مدل‌ها استفاده شده است. نتایج آزمایش‌ها در این تحقیق نشان می‌دهد، مدل ترکیبی بهترین پیش‌بینی را داشته است و مدل LSTM اگر چه بدترین پیش‌بینی را بین این سه مدل داشته ولی زمان اجرای کمتری داشته است. در این تحقیق، همچنین در خصوص بازه زمانی در نظر گرفته شده برای مجموعه آموزشی نیز بررسی انجام گرفته است. طبق نتایج آزمایش‌ها اگر طول دنباله زمانی بین بازه یک تا سه سال افزایش یابد نتایج مدل‌ها بهبود پیدا می‌کند. اما از 3 سال بیشتر

واحد فتوولتائیک از جمله موقعیت جغرافیایی، پیکربندی و ساختار فیزیکی سلول‌های خورشیدی هستند؛ (2) روش‌های مبتنی بر داده: در این روش‌ها از تکنیک‌های آماری و یا الگوریتم‌های یادگیری ماشین استفاده می‌شود [6]. پیرو و همکاران نشان دادند در پیش‌بینی توان PV تولیدی روز آینده، روش‌های مبتنی بر داده بهتر از روش‌های قطعی عمل می‌کنند [6].

به طور کلی وجود پارامترهای تاثیر گذار متنوع و پیچیدگی این سیستم‌ها همچنین وجود عدم قطعیت در شرایط موجود سبب شده است که نتوان به مقاوم بودن نتایج حاصل از متدهای قطعی اطمینان داشت [7]. آزکا و همکارانش تاثیر عوامل مختلف محیطی از جمله میزان دما، رطوبت یا میزان باد را بر خروجی توان فتوولتائیک بررسی کردند [7]. در این پژوهش از دو مدل مبتنی بر شبکه عصبی استفاده شده است که در مدل اول از یک لایه پنهان و در مدل دوم از دو لایه پنهان استفاده شده است. آنها نشان دادند که وجود دو لایه پنهان، کارایی مدل را بالاتر برده است. ورودی‌های مدل متغیرهای محیطی از جمله دما، رطوبت، فشار و میزان پوشش ابر می‌باشد. در [8] فاکتورهای مختلف تاثیر گذار در پیش‌بینی توان فتوولتائیک، مورد بررسی قرار گرفته است. این فاکتورها شامل میزان تابش، دما، رطوبت و فشار است. نتایج آزمایش‌ها در این تحقیق نشان می‌دهد، تاثیر فاکتورهای محیطی در فصل‌های مختلف متفاوت است و در نتیجه در پیش‌بینی‌ها باید به این نکته توجه شود. ون‌تای از چند مدل مبتنی بر روش‌های یادگیری ماشین از جمله k-نزدیکترین همسایه، رگرسیون، درخت تصمیم و شبکه عصبی برای پیش‌بینی توان خروجی استفاده کرده و پارامترهایی مثل میزان دما، میزان باد و میزان تابش را به عنوان ورودی مدل به کار برده است [9].

ونگ و همکارانش [10] در مدل‌های پیش‌بین، از ویژگی‌های آب و هوایی به طور مستقیم استفاده نکرده‌اند. آنها برای شرایط آب و هوایی، بر اساس میزان توان تولیدی، چهار حالت تعریف کرده‌اند (A, B, C, D). نوع A مناسب‌ترین دما برای تولید برق و نوع D بدترین حالت برای تولید است. با توجه به تعریف فوق، برای بازه‌های دوساعته، برچسب نوع آب و هوا به داده‌های آموزشی اضافه می‌شود و یک طبقه‌بند درختی با این داده‌ها آموزش می‌یابد تا بتواند بر اساس شرایط آب و هوایی نوع آب و هوا را تشخیص دهد. در نهایت نوع آب و هوایی مربوط به زمان‌های قبل را به عنوان ورودی به مدل داده و خروجی PV را تخمین زده‌اند.

در سال‌های اخیر، یادگیری عمیق به عنوان یک زمینه تحقیقاتی امیدوار کننده چه در حوزه تحقیقات آکادمیک و چه در حوزه صنعت مورد توجه بسیاری از محققان قرار گرفته است. تکنولوژی یادگیری عمیق کاربردهای فراوانی از جمله بینایی ماشین، پردازش زبان طبیعی و تشخیص گفتار دارد. روش‌های یادگیری عمیق، تحولی بزرگ در پردازش سری‌های زمانی ایجاد کرده‌اند. وجود چندین لایه پنهان به این شبکه‌ها کمک می‌کند تا بتوانند ارتباطها و روابط نهفته بین متغیرهای یک مدل را بدون دخالت انسان تشخیص دهند. در تحقیقات، مدل‌های زیادی مبتنی بر شبکه‌های عصبی عمیق برای پیش‌بینی توان خروجی سیستم‌های فتوولتائیک ارائه شده است. در [11] نشان داده شده است که روش مبتنی بر شبکه عصبی عمیق (LSTM¹) نسبت به روش بردار ماشین در یک سیستم فتوولتائیک در اسپانیا دقت پیش‌بینی بالاتری دارد.

2. Variational Auto-Encoder
3. Wavelet Packet Decomposition
4. Convolutional Neural Network

1 Long Short-Term Memory

پس از فرایند خود رمزنگاری، با سایر ویژگیهای مهندسی شده ترکیب شده و به LSTM داده می‌شوند.

کرکماز از ایده تجزیه سری زمانی استفاده کرده است در مدل پیشنهادی‌اش CNN را به تجزیه سری زمانی مجهز کرده است [20]. معماری مدل شامل چهار مرحله است. در ابتدا به کمک روش VMD⁸، دنباله توانهای فتوولتاییک تجزیه می‌شود و سری‌هایی با فرکانسهای فرعی به دست می‌آید. سپس این سری‌های زمانی به فضایی دوبعدی نگاشت داده می‌شوند و به صورت یک تصویر RGB در کنار هم قرار می‌گیرند. این فرایند سبب ایجاد یک ورودی جدید می‌شود که وابستگی‌های ساعت و روزها را در بردارد. در مرحله سوم (مرحله آموزش)، ابتدا تصویرهای ورودی به کمک دولایه موازی تجمع⁹ (maxPooling و averagePooling) ساده‌تر می‌شوند. خروجی ترکیب شده این دو لایه موازی به لایه‌های پشت سرهم پیچشی¹⁰ و تجمع وارد شده و به کمک روش پس انتشار خطا، شبکه آموزش می‌بیند. مرحله آخر تست و ارزیابی مدل است.

در [21] از یک مدل گروهی¹¹ مبتنی بر یادگیری عمیق استفاده شده است. در یک مدل گروهی، چند مدل پایه جداگانه آموزش می‌بینند و در نهایت نتایج آنها با هم ترکیب می‌شود تا مسئله نهایی حل شود. روش‌های گروهی بر این اصل ایجاد شده‌اند که صحت مدل گروهی معمولاً از صحت مدل‌های پایه بالاتر خواهد بود. به طور مثال در [22] از دو مدل پایه SVM و ANN¹² برای ساخت مدل گروهی جهت پیش‌بینی توان استفاده شده است. در [21] مدل‌های پایه LSTM و ANN می‌باشند.

در مرجع [23] به منظور افزایش تفسیرپذیری مدل و بالا بردن دقت پیش‌بینی از تکنیک فازی بهره برده شده است. اگرچه پیش از ارائه این مقاله هم از فازی برای پیش‌بینی توان فتوولتاییک استفاده شده بود، اما یادگیری در آنها عمیق نبوده است. بنابراین نویسندگان این مقاله، مدل¹³ DIRM_DFM که یک مدل فازی ماژولار است را ارائه کرده‌اند. مدل پیشنهاد شده، پشته‌ای از لایه‌های DIRM است. لایه پایینی با ورودی‌های اصلی در ارتباط است؛ هر دو ورودی به یک DIRM وارد می‌شود. بنابراین اگر n ورودی وجود داشته باشد، به تعداد $(n-1)$ DIRM وجود دارد. همچنین در هر لایه میانی، ورودی هر DIRM، خروجی دو DIRM از لایه قبل خواهد بود. در هر لایه DIRMها به صورت موازی آموزش می‌بینند. بنابراین مقاومت مدل بالاست. زیرا اگر یک DIRM هم دچار مشکل شود، خروجی بقیه DIRMها آن را جبران کرده و دقت نهایی را حفظ می‌کنند. آموزش هر DIRM به کمک روش حداقل مربعات محدود انجام می‌شود.

3- روش پیشنهادی

هدف از این تحقیق، تحلیل و پردازش داده‌های مربوط به نیروگاه خورشیدی کوشک یزد می‌باشد. نیروگاه کوشک یزد چهارمین نیروگاه خورشیدی ۱۰ مگاواتی در کشور است که در آن از ۲۷ هزار و ۸۶۸ صفحه پنل خورشیدی استفاده شده که هر یک از این صفحات ظرفیتی معادل ۳۸۵ وات دارند. صفحات مذکور در زمینی به مساحت ۲۰ هکتار با بیشترین میزان تابش

نتیجه بدتر خواهد شد. بنابراین اگر داده‌های مربوط به سه سال اخیر، برای آموزش مدل استفاده شود بهترین نتیجه را در بر خواهد داشت.

زائولی و همکارانش از شبکه LSTM برای پیش‌بینی توان در سیستم‌های برق خورشیدی خانگی استفاده کرده‌اند [16]. پن و همکارانش به منظور بهبود نتایج پیش‌بینی توان فتوولتاییک، شبکه عصبی LSTM را با مکانیزم توجه ترکیب کرده‌اند [17]. در این تحقیق ابتدا به کمک روش خودهمبستگی جزئی^۱ طول مناسب برای توالی ورودی به LSTM را تخمین می‌زنند. بر اساس این روش، بهترین مقدار برای طول توالی ورودی برای داده‌های مورد استفاده قرار گرفته شده در این مقاله عدد چهار است. ابتدا از LSTM برای ساخت مدل پیش‌بین با دنباله زمانه ورودی از طول k استفاده می‌شود و خروجی پنهان شبکه در زمان‌های مختلف محاسبه می‌شود. سپس توجه زمانی^۲ به کمک یک لایه خطی و تابع softmax محاسبه می‌شود. این لایه وزن مربوط به ورودی‌های شبکه LSTM را مشخص می‌کند. وجود لایه softmax این اطمینان را می‌دهد که مجموع وزنها یک شود. با ضرب وزنها در خروجی‌های LSTM ورودی لایه نهایی تولید می‌شود. نتیجه به یک تابع فعالساز ReLU³ فرستاده می‌شود و در نهایت به کمک یک لایه خطی می‌توان پیش‌بینی نهایی را انجام داد.

در [18] از ترکیب LSTM و شبکه کانولوشن برای پیش‌بینی توان استفاده شده است. ابتدا ویژگیهای زمانی در داده‌ها توسط LSTM مدل می‌شود و سپس ویژگیهای مکانی توسط مدل کانولوشنی استخراج می‌شود. در این تحقیق نشان داده شده است که این مدل ترکیبی نسبت به مدل‌های مجزای LSTM و CNN همچنین مدل ترکیبی که ابتدا CNN باشد و بعد LSTM بهتر عمل می‌کند.

ژنگ و همکارانش برای پیش‌بینی توان تولیدی در روز آینده، مدلی ارائه کرده‌اند که ترکیبی از خودرمزنگار و LSTM است [19]. در این مدل فرض شده است که در روزهای آفتابی پشت سر هم، از آنجاییکه تنظیمات سلول‌های خورشیدی و همچنین میزان تابش یکسان است، میزان خروجی فتوولتاییک در ساعت‌های یکسان تقریباً یکسان خواهد بود. بنابراین ابتدا چک می‌کند اگر روز آینده کاملاً آفتابی است از یک مدل ثابت برای پیش‌بینی استفاده کرده در غیر این صورت از مدل AE-LSTM استفاده می‌کنند. همچنین با ورود داده‌های جدید مدل AE-LSTM به روزرسانی می‌شود. در این روش از مهندسی ویژگی^۴ نیز برای بهبود کارایی مدل استفاده شده است. اگرچه مدل‌های مبتنی بر شبکه عصبی عمیق می‌توانند به طور خودکار ویژگیها را استخراج کنند؛ اما همچنان نیاز به مهندسی ویژگی وجود دارد. زیرا در عمل ممکن است استخراج ویژگی مناسب خیلی زمانبر باشد. از طرفی انتخاب ویژگی‌های مناسب سبب کاهش حجم داده ورودی نیز می‌شود. در این مقاله از RMSEDD^۵ برای انتخاب ویژگی استفاده شده و نشان داده شده است که چهار ویژگی توان‌های تولید شده در زمان‌های قبل، دما، تابش خورشید^۶ و زاویه اوج خورشیدی^۷ تاثیرگذارترین فاکتورها در مدل پیشنهادی هستند. در این مدل، توانهای خروجی قبل (تعداد نمونه‌ها برابر با 96 است)

8. Variational Mode Decomposition

9. Pooling

10. Convolutional

11. Ensemble Model

12. Artificial Neural Network

13. Double-Input-Rule-Modules (DIRMs) stacked Deep Fuzzy Model

1. Partial Autocorrelation

2. Temporal Attention


3. Rectified Linear Unit

4. Feature Engineering

5. Root Mean Squared Euclidean Distance Difference

6. Solar radiation

7. Solar Zenith Angle



شکل 3 مصور سازی توان خروجی از بازه 21/10 الی 22/2 پس از حذف داده‌های پرت

3-1-2 اطلاعات مربوط به وضعیت آب و هوایی در زمان‌های مختلف

شرایط آب و هوایی تاثیر مستقیم بر میزان توان خروجی در پنل‌های خورشیدی دارد. به طور مثال افزایش دما، تاثیر منفی در کارایی سلول‌های خورشیدی دارد. در مقابل باد اگر باعث شکستگی پنل‌ها نشود، می‌تواند باعث خنک‌تر شدن پنل و در نتیجه افزایش حجم توان تولید شده شود. بنابراین جهت پیش‌بینی دقیق‌تر سعی شده است، از این اطلاعات در این تحقیق استفاده شود. اطلاعات آب و هوایی از قبیل دما و سرعت باد برای یک بازه سه ماهه از یک ایستگاه هواشناسی در نزدیکی نیروگاه گرفته شده است. با توجه به مسائل امنیتی، امکان ارتباط مستقیم با سرور هواشناسی مهیا نشد و تنها نمودارها در اختیار ما قرار گرفته است.

به منظور تبدیل این نمودارها به داده‌های عددی از سایت هواشناسی Stormglass¹ کمک گرفته‌ایم. این سایت علاوه بر پیش‌بینی آب و هوا برای 10 روز آینده، اطلاعات پیش‌بینی تمام پارامترهای آب و هوایی را نیز در اختیار ما قرار می‌دهد. API ای که این سایت ایجاد کرده است، این امکان را دارد که برای هر مختصات جغرافیایی، اطلاعات آب و هوا را در بازه تاریخی مورد نظر، در قالب JSON برگرداند. جدول 1 نمونه ای از متغیرهای آب و هوایی که این سایت در اختیار ما می‌گذارد را نشان می‌دهد.

جدول 1 پارامترهای آب و هوایی قابل استخراج از سایت Stormglass

نام پارامتر	توصیف
time	برچسب زمانی
airTemperature	دمای هوا با درجه سانتی گراد
pressure	فشار هوا
cloudCover	درصد پوشش ابر
gust	وزش باد بر حسب متر بر ثانیه
humidity	درصد رطوبت
precipitation	میانگین بارش
windDirection	جهت وزش باد در ارتفاع 10 متری از سطح دریا
windSpeed	سرعت باد در ارتفاع 10 متری از سطح دریا


1. <https://stormglass.io/>

خورشید نصب شده‌اند. داده‌های لازم برای انجام این تحقیق توسط خروجی‌های نرم افزار مانیتورینگ این واحد جمع آوری شده است. با توجه به تازه تاسیس بودن این نیروگاه، داده کافی برای پیش‌بینی‌های دقیق بلند مدت و میان مدت وجود ندارد. بنابراین هدف از این تحقیق، ایجاد یک مدل برای پیش‌بینی کوتاه مدت توان تولیدی در این نیروگاه است. در ادامه، در خصوص آماده سازی داده‌ها، معماری و ساختار مدل پیشنهادی توضیحاتی بیان خواهد شد.


3-1-3 آماده سازی داده‌ها

3-1-3-1 اطلاعات مربوط به توان تولیدی در زمان‌های مختلف


همانطور که گفته شد، اطلاعات مربوط به توان تولیدی در قالب فایل‌های CSV از نرم افزار مانیتورینگ نیروگاه گرفته شده است. به منظور بررسی اولیه داده‌ها، از مصور سازی استفاده شد. بر اساس شکل 1 و 2 مشخص شد که بعضی از مقادیر توان خروجی، در بازه مجاز قرار نگرفته‌اند و باید به عنوان داده پرت از داده‌ها حذف شوند. به عنوان مثال مقادیر مربوط به توان خروجی در روزهای 2022/1/2 و یا 2022/1/25 در بازه درست قرار ندارند. بنابراین این روزها به عنوان داده‌های پرت حذف گردیدند. شکل 3 نشان می‌دهد که پس از پیش‌پردازش، داده‌های پرت به درستی حذف شده‌اند.



شکل 1 مصور سازی توان خروجی از بازه 21/10 الی 22/2



شکل 2 مصور سازی توان خروجی از بازه 22/1/1 الی 22/2/1




شکل 5 ساختار مدل مبتنی بر LSTM (مدل 1)

روش LSTM (مدل 2)

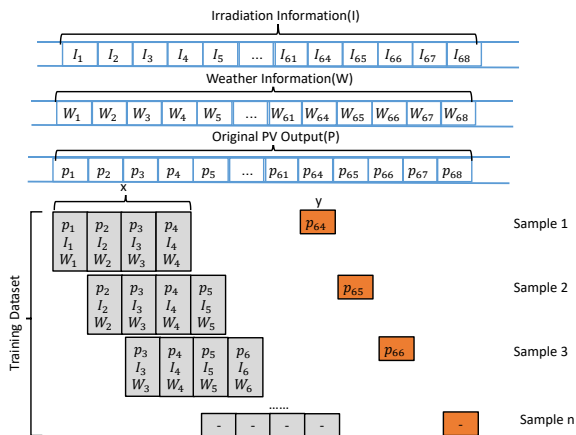
میزان توان تولید شده در نیروگاه های خورشیدی به شرایط آب و هوایی و میزان تابش خورشیدی وابسته است بنابراین می توان با استفاده از اطلاعات هواشناسی موجود پیش بینی مدل را بهبود داد. در مدل پیشنهادی دوم، شبکه LSTM وظیفه دارد، علاوه بر توانهای تولید شده قبل، از اطلاعات هواشناسی نیز برای پیش بینی بهتر استفاده کند (شکل 6). در این مدل برای پیش بینی توان روز d در لحظه $m + 60$ از اطلاعات مربوط به زمان های قبلی کمک گرفته می شود ($X = [q_d^m, q_d^{m-1}, \dots, q_d^{m-F}]$). به عبارت دیگر اطلاعات مربوط به F لحظه قبل مورد استفاده قرار می گیرد. این اطلاعات شامل ترکیبی از اطلاعات توان خروجی در لحظه های قبل، میزان تابش و اطلاعات هواشناسی است:

$$q_d^m = p_d^m + I_d^m + w_d^m \quad (1)$$

در این رابطه p_d^m اطلاعات مربوط به توان خروجی در لحظه m ، I_d^m اطلاعات مربوط به میزان تابش در لحظه m و w_d^m اطلاعات مربوط به هواشناسی در لحظه m می باشد. همچنین منظور از عملگر $+$ در این فرمول، در کنار هم قرار دادن این بردارهاست. شکل 7 این مرحله را با $F=4$ نشان می دهد. اطلاعات مربوط به F زمان قبل به شبکه LSTM وارد شده و خروجی شبکه میزان توان تولیدی خواهد بود.



شکل 6 ساختار مدل مبتنی بر LSTM (مدل 2)



بنابراین رویکرد اصلی در این پروژه بر این اساس است که ابتدا داده های آب و هوایی به کمک API فراهم شده در سایت Stormglass استخراج می گردد و پس از تبدیل خروجی به فرمت CSV، نمودار استخراج شده از سایت Stormglass، با نمودارهای اصلی (مربوط به ایستگاه هواشناسی نیروگاه) مقایسه شده و در صورت وجود تفاوت به صورت دستی داده ها اصلاح شوند.

3-2- ساخت مدل پیش بین

با استفاده از روش های مختلف یادگیری ماشین می توان مدل های متنوعی برای پیش بینی توان ایجاد کرد. در این بخش، روش های پیشنهادی توضیح داده شده است.

روش LSTM (مدل 1)

LSTM یک نسخه اصلاح شده از شبکه ی عصبی RNN¹ است که در آن، به خاطر سپردن داده های گذشته در حافظه آسان تر شده و همچنین مشکل ناپدید شدن گرادیان، در این روش حل شده است. LSTM برای طبقه بندی، پردازش و پیش بینی سری های زمانی با توجه به تاخیرهای زمانی ناشناخته مناسب است. این مدل با استفاده از پس انتشار، آموزش می بیند.

در مدل اول تنها از توانهای تولید شده قبل برای پیش بینی توان استفاده می کنیم. برای ایجاد داده های آموزشی، دنباله زمانی توانهای برق خروجی به توالی هایی تقسیم میشود. که هر توالی یک نمونه از داده های آموزشی را تشکیل می دهد. برای ساخت این توالی ها از یک پارامتر به نام F استفاده می شود که طول پنجره زمانی که به عنوان ورودی در نظر گرفته شده است را نشان می دهد. به عبارت دیگر، قرار است بر اساس F توان خروجی اخیر توان یک ساعت بعد را پیش بینی کرد. بنابراین اگر ورودی به صورت $p = \{p_{m-F}, p_{m-F+1}, \dots, p_{m-1}, p_m\}$ در نظر گرفته شود، خروجی، توان تولید شده در یک ساعت بعد خواهد بود ($y = p_{m+60}$). طول توالی (F) یک پارامتر مهم است که در این تحقیق 20 در نظر گرفته شده است. شکل 4 نمایی از سری توانهای PV تولید شده (P) و نمونه توالی های تولید شده به عنوان داده های آموزشی را نشان می دهد. در این مثال پنجره زمانی ($F=4$) در نظر گرفته شده است و هدف پیش بینی توان یک ساعت بعد است. بنابراین اگر فرض شود ورودی توان تولید شده در لحظه های 1، 2، 3 و 4 است خروجی دلخواه توان در لحظه 64 خواهد بود. در این مدل ها فرض بر این است که توان تولیدی در ساعت هایی که تابش وجود ندارد صفر است. نمایی از مدل مورد استفاده در این روش در شکل 5 نشان داده شده است.


شکل 4 چگونگی ایجاد مجموعه داده آموزشی به کمک داده های سری زمانی - در این مثال $F=4$ در نظر گرفته شده است و هدف پیش بینی توان 60 دقیقه بعد است

1. Recurrent Neural Network


شکل 7 چگونگی ایجاد مجموعه داده آموزشی (در مدل دوم) به کمک داده‌های سری زمانی- در این مثال $F=4$ در نظر گرفته شده است و هدف، پیش‌بینی توان 60 دقیقه بعد است

روش LSTM (مدل 3)


به منظور بهبود روش دوم، در مدل سوم ساختار شبکه عصبی را کمی پیچیده‌تر کرده و از سه لایه LSTM استفاده کرده‌ایم. نمایی از ساختار این شبکه در شکل 8 نشان داده شده است. علاوه بر تغییر فوق، در این مدل تعداد مراحل آموزش شبکه را افزایش داده‌ایم.



شکل 9 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از توان تولید شده در 20 دقیقه قبل



شکل 10 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از توان تولید شده در 20 دقیقه قبل (با وضوح بالاتر)



شکل 8 ساختار مدل مبتنی بر LSTM (مدل 3)

4- ارزیابی روش پیشنهادی

برای ارزیابی مدل، داده‌های آموزشی به دو قسمت آزمایشی و تست تقسیم شده‌اند. یک سوم داده‌ها برای تست و بقیه برای آموزش مدل استفاده شده است. تمام مدل‌ها به زبان پایتون پیاده‌سازی شده‌اند. معیار ارزیابی $RMSE^1$ است، که برابر است با جذر میانگین مربعات خطای پیش‌بینی و با فرمول زیر محاسبه می‌شود:

$$RMSE = \sqrt{(o-p)^2} \quad (2)$$

که در این فرمول o توان خروجی واقعی و p توان پیش‌بینی شده است.


4-1 نتایج پیش‌بینی برای مدل 1

نتایج پیش‌بینی توان خروجی توسط مدل اول برای چند روز در شکل 9 و 10 نشان داده شده است. در این آزمایش‌ها نرخ نمونه برداری یک دقیقه انتخاب شده است. مدل بر اساس 135168 نمونه آموزشی که هر کدام یک ماتریس 3×20 است آموزش داده شده است. هر نمونه شامل اطلاعات توان، روز و ساعت مربوط به 20 دقیقه قبل است و خروجی توان یک ساعت بعد خواهد بود. همانطور که در این تصاویر مشهود است، مدل توانسته است به میزان قابل قبولی در روزهای آفتابی و ابری پیش‌بینی داشته باشد. مقدار $RMSE$ به دست آمده در این مدل، $2/471$ می‌باشد.


4-2 نتایج پیش‌بینی برای مدل 2

ورودی در این مدل یک ماتریس 10×20 است. به عبارت دیگر هر نمونه اطلاعات توان، روز و ساعت مربوط به 20 دقیقه جاری را دارد. علاوه بر این، اطلاعات هواشناسی از جمله دما، میزان رطوبت و پوشش ابر و همچنین میزان تابش خورشید در این 20 دقیقه را نیز خواهد داشت. خروجی دلخواه، توان یک ساعت بعد خواهد بود. نتایج به دست آمده از این مدل برای چند روز در شکل 11 و 12 نشان داده شده است. مقدار $RMSE$ در این مدل $1/018$ است.

1. Root Mean Square Error




شکل 14 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از اطلاعات هواشناسی و توان تولید شده در 20 دقیقه قبل، با وضوح بالاتر (مدل سوم)




شکل 11 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از اطلاعات هواشناسی و توان تولید شده در 20 دقیقه قبل (مدل دوم)

همچنین به منظور دریافت اطلاعات بیشتر از گذشته، از اطلاعات مربوط به پنجره زمانی 6 ساعته (360 دقیقه) فعلی برای پیش‌بینی توان یک ساعت بعد استفاده شده است. با توجه به این شرایط بار دیگر مدل آموزش داده شده است. نتایج بدست آمده توسط این مدل با در نظر گرفتن پنجره زمانی 360 دقیقه جاری برای تخمین توان یک ساعت بعد، در شکل 15 و 16 نشان داده شده است. مقدار RMSE در این حالت 0/904 به دست آمد که نسبت به مدل‌های قبل بهبود داشته است.




شکل 12 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از اطلاعات هواشناسی و توان تولید شده در 20 دقیقه قبل، با وضوح بالاتر (مدل دوم)



شکل 15 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از اطلاعات هواشناسی و توان تولید شده در 360 دقیقه قبل (مدل سوم)

3-4 - نتایج پیش‌بینی برای مدل 3

نتایج بدست آمده توسط مدل 3 با در نظر گرفتن پنجره زمانی 20 دقیقه جاری برای تخمین توان یک ساعت بعد، در شکل 13 و 14 داده شده است. RMSE در این حالت مقدار 0/909 به دست آمده است.




شکل 13 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از اطلاعات هواشناسی و توان تولید شده در 20 دقیقه قبل (مدل سوم)

6- تقدیر و تشکر

این تحقیق نتیجه یک طرح پژوهشی تحت عنوان "پیش‌بینی کوتاه مدت توان فتوولتائیک در نیروگاه خورشیدی کوشک" مصوب دانشگاه بجنورد با شماره 0033-3000 در سال 1400 می‌باشد که با حمایت مالی شرکت کنترل و پردازش هوشمند انجام شده است. مجموعه داده مورد استفاده در این تحقیق توسط شرکت کرچنر سولار گروپ ایرانیان¹ و شرکت کنترل و پردازش هوشمند فراهم شده است.

7- مراجع

- [1] A. El hendouzi and A. Bourouhou, Solar photovoltaic power forecasting, *Journal of Electrical and Computer Engineering*, Vol. 2020, No. 1, pp. 1–21, 2020.
- [2] M. Q. Raza, M. Nadarajah, and C. Ekanayake, On recent advances in PV output power forecast, *Solar Energy*, Vol. 136, No. 1, pp. 125–144, 2016.
- [3] G. Li, S. Xie, B. Wang, J. Xin, Y. Li, and S. Du, Photovoltaic power forecasting with a hybrid deep learning approach, *IEEE Access*, Vol. 8, No. 1, pp. 175871–175880, 2020.
- [4] S. Theocharides, G. Makrides, G. E. Georgiou, and A. Kyprianou, Machine learning algorithms for photovoltaic system power output prediction, in *IEEE International Energy Conference (ENERGYCON)*, pp. 1–6, Limassol, Cyprus 2018.
- [5] P. Li, K. Zhou, X. Lu, and S. Yang, A hybrid deep learning model for short-term PV power forecasting, *Applied Energy*, Vol. 259, No. 1, pp. 114216.1–114216.11, 2020.
- [6] M. Pierro, F. Bucci, M. D. Felice, E. Maggioni, A. Perotto, F. Spada, D. Moser, and C. Cornaro, Deterministic and stochastic approaches for day-ahead solar power forecasting, *Journal of Solar Energy Engineering*, Vol. 139, No. 2, pp. 021010.1–021010.12, 2017.
- [7] R. Azka, W. Soefian, D. R. Aryani, F. H. Jufri, and A. R. Utomo, Modelling of photovoltaic system power prediction based on environmental conditions using neural network single and multiple hidden layers, in *IOP Conference Series: Earth and Environmental Science*, Vol. 599, No. 1, pp. 012032.1–012032.6, Bangka Belitung Islands, Indonesia, 2020.
- [8] D. Matushkin, A. Bosak, and L. Kulakovskiy, Analysis of factors for forecasting electric power generation by solar power plants, *Power Engineering: Economics, Technique, Ecology*, Vol. 62, No. 4, pp. 64–69, 2020.
- [9] D. Van Tai, Solar photovoltaic power output forecasting using machine learning technique, *Journal of Physics: Conference Series*, 2019, Vol. 1327, No. 1, pp. 012051.1–012051.5, 2019.
- [10] X. Wang, Y. Sun, D. Luo, and J. Peng, Comparative study of machine learning approaches for predicting short-term photovoltaic power output based on weather type classification, *Energy*, Vol. 240, No. 1, pp. 122733.1–122733.15, 2022.
- [11] M. A. F. B. Lima, L. M. Fernández Ramírez, P. C. M. Carvalho, J. G. Batista, and D. M. Freitas, A comparison between deep learning and support vector regression techniques applied to solar forecast in Spain, *Journal of Solar Energy Engineering*, Vol. 144, No. 1, pp. 010802.1–010802.9, 2021.
- [12] A. Dairi, F. Harrou, Y. Sun, and S. Khadraoui, Short-term forecasting of photovoltaic solar power production using variational auto-encoder driven deep learning approach, *Applied Sciences*, Vol. 10, No. 23, pp. 8400.1–8400.20, 2020.
- [13] X. G. Agoua, R. Girard, and G. Kariniotakis, Photovoltaic power forecasting: assessment of the impact of multiple sources of spatio-temporal data on forecast accuracy, *Energies*, Vol. 14, No. 5, pp. 1432.1–1432.15, 2021.
- [14] G. Almonacid-Olleros, G. Almonacid, J. I. Fernandez-Carrasco, and J. M. Quero, Opera.DL: deep learning modelling for photovoltaic system monitoring, in *Multidisciplinary Digital*



شکل 16 توان پیش‌بینی شده یک ساعت بعد در برابر توان واقعی با استفاده از اطلاعات هواشناسی و توان تولید شده در 360 دقیقه قبل، با وضوح بالاتر (مدل سوم)

5- نتیجه گیری و کارهای آینده

امروزه نیروگاه‌های خورشیدی با هدف کاهش وابستگی به سوخت‌های فسیلی و در نتیجه کاهش آلودگی‌های زیست محیطی مورد توجه بسیاری از کشورها قرار گرفته است. با وجود تمام مزایایی که انرژی خورشیدی دارد، میزان توان تولیدی فتوولتائیک در این نیروگاه‌ها قابل کنترل نیست و به شرایط محیطی وابسته است. از آنجایی که برای ادغام این نیروگاه‌ها در شبکه توزیع برق سراسری، نیاز به برنامه ریزی در خصوص تقسیم بار بین نیروگاه‌ها وجود دارد اطلاع از میزان توان خروجی در زمان آینده برای یک نیروگاه می‌تواند بسیار حائز اهمیت باشد. در این تحقیق، سه نوع مدل پیش‌بین، مبتنی بر شبکه LSTM معرفی شده است. مدل اول و دوم که در آنها از یک لایه شبکه LSTM استفاده شده است، بر اساس پنجره زمانی با طول 20 دقیقه جاری، توان تولیدی یک ساعت بعد را پیش‌بینی می‌کنند. در مدل اول تنها از توان‌های خروجی در زمان‌های قبل به عنوان ورودی استفاده می‌شود و در مدل دوم علاوه بر اطلاعات توان در زمان‌های قبل، از میزان تابش و اطلاعات هواشناسی نیز استفاده شده است. در مدل سوم از سه لایه LSTM استفاده شده و با دو حالت پنجره زمانی 20 دقیقه و پنجره زمانی 360 دقیقه (6 ساعت) مدل آموزش می‌بیند. نتایج به دست آمده در آزمایش‌ها نشان می‌دهد، مدل‌های پیشنهادی با دقت مناسبی توانسته‌اند توان خروجی را برای یک ساعت بعد تخمین بزنند. همچنین استفاده از اطلاعات هواشناسی و میزان تابش توانسته است دقت پیش‌بینی را در مدل دوم و سوم بالاتر ببرد. علاوه بر این، افزودن لایه‌های شبکه عصبی عمیق و همچنین استفاده از طول پنجره زمانی بزرگتر در مدل سوم به افزایش دقت پیش‌بینی منجر شده است. در این تحقیق از یک ساختار ساده در شبکه عصبی استفاده شده است. استفاده از ساختارهای متنوع دیگر در شبکه می‌تواند به بهبود نتایج پیش‌بینی کمک کند. در ادامه قصد داریم با ترکیب روش‌ها و همچنین استفاده از ساختارهای پیچیده‌تر دقت مدل پیشنهادی را بالاتر ببریم. در حال حاضر امکان دسترسی به اطلاعات پیش‌بینی هواشناسی برای زمان‌های آینده وجود دارد و این اطلاعات می‌تواند منبع ارزشمندی برای بهبود پیش‌بینی مدل باشد. در ادامه قصد داریم به کمک این داده‌ها مدل پیش‌بین را بهبود بخشیم.

- Publishing Institute Proceedings*, Vol. 31, No. 1, pp. 50.1–50.10, Toledo, Spain, 2019.
- [15] K. Wang, X. Qi, and H. Liu, A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network, *Applied Energy*, Vol. 251, No. 1, pp. 113315.1–113315.15, 2019.
- [16] K. Zaouali, R. Rekik, and R. Bouallegue, Deep learning forecasting based on auto-LSTM model for home solar power systems, in *IEEE 16th International Conference on Smart City*, pp. 235–242, Exeter, UK, 2018.
- [17] C. Pan, J. Tan, D. Feng, and Y. Li, Very short-term solar generation forecasting based on LSTM with temporal attention mechanism, in *IEEE 5th International Conference on Computer and Communications (ICCC)*, pp. 267–271, Chengdu, China, 2019.
- [18] K. Wang, X. Qi, and H. Liu, Photovoltaic power forecasting based LSTM-convolutional network, *Energy*, Vol. 189, No. 1, pp. 116225.1–116225.11, 2019.
- [19] Y. Zhang, C. Qin, A. K. Srivastava, C. Jin, and R. K. Sharma, Data-driven day-ahead PV estimation using autoencoder-LSTM and persistence model, *IEEE Transactions on Industry Applications*, Vol. 56, No. 6, pp. 7185–7192, 2020.
- [20] D. Korkmaz, SolarNet: A hybrid reliable model based on convolutional neural network and variational mode decomposition for hourly photovoltaic power forecasting, *Applied Energy*, Vol. 300, No. 1, pp. 117410.1–117410.20, 2021.
- [21] W. Khan, S. Walker, and W. Zeiler, Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach, *Energy*, Vol. 240, No. 1, pp. 122812.1–122812.16, 2022.
- [22] M. Pierro *et al.*, Multi-model ensemble for day ahead prediction of photovoltaic power generation, *Solar Energy*, Vol. 134, No. 1, pp. 132–146, 2016.
- [23] C. Li, C. Zhou, W. Peng, Y. Lv, and X. Luo, Accurate prediction of short-term photovoltaic power generation via a novel double-input-rule-modules stacked deep fuzzy method, *Energy*, Vol. 212, No. 1, pp. 118700.1–118700.13, 2020.