

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Alen Jakoplić

**KRATKOROČNO PREDVIĐANJE PROIZVODNJE
FOTONAPONSKIH ELEKTRANA UPORABOM
KONVOLUCIJSKE NEURONSKE MREŽE**

DOKTORSKI RAD

Rijeka, 2023.

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Alen Jakoplić

**KRATKOROČNO PREDVIĐANJE PROIZVODNJE
FOTONAPONSKIH ELEKTRANA UPORABOM
KONVOLUCIJSKE NEURONSKE MREŽE**

DOKTORSKI RAD

Mentor: prof. dr. sc. Dubravko Franković

Rijeka, 2023.

UNIVERSITY OF RIJEKA
FACULTY OF ENGINEERING

Alen Jakoplić

**SHORT-TERM FORECASTING OF PHOTOVOLTAIC
POWER PLANT OUTPUT USING CONVOLUTIONAL
NEURAL NETWORK**

DOCTORAL DISSERTATION

Rijeka, 2023.

Mentor doktorskog rada: prof. dr. sc. Dubravko Franković, Sveučilište u Rijeci, Tehnički fakultet

Doktorski rad obranjen je dana _____ na Tehničkom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. izv. prof. dr. sc. Rene Prenc, Tehnički fakultet, Sveučilište u Rijeci
2. Prof. dr. sc. Saša Vlahinić, Tehnički fakultet, Sveučilište u Rijeci
3. Prof. dr. sc. Juraj Havelka, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu

ZAHVALA

Velika mi je čast ovu zahvalu započeti izražavajući iznimno zadovoljstvo i zahvalnost svima koji su na bilo koji način doprinijeli istraživačkom radu i pisanju ovog doktorskog rada.

Iskreno i prvo želim zahvaliti svom mentoru, prof. dr. sc. Dubravku Frankoviću, čije je stručno vođenje, strpljenje, poticajne sugestije i vjera u sve što smo gradili, temelj mog uspjeha i ovog doktorskog rada. Svojim primjerom razvijao je moju volju, želju i strast za istraživačkim radom, te je kroz sve izazove bio velika podrška i putokaz prema napredovanju i uspjehu. Neizmijerna mi je čast raditi s Vama.

Zahvaljujem se i svim članovima Odbora na stručnom znanju, konstruktivnim raspravama i informacijama koje su uvelike pridonijele kvaliteti ovog rada.

Također, veliku zahvalu dugujem i svojoj obitelji. Beskrajno hvala na ljubavi, poticaju, strpljenju i podršci. Bez vas, ovaj rad ne bi bio moguć niti imao smisao.

Posebnu zahvalu dugujem i svojoj ženi koja je na ovom valovitom putu bila moja sigurna luka.

Ovaj rad plod je truda i rada kako mene, tako i svih koji su sudjelovali u njegovom začetku, razvijanju i kreiranju.

Sve što danas jesam, dugujem vama koji su mi pomogli stvarati i razvijati ono što je bilo utkano u mene.

Hvala vam.

SAŽETAK

U posljednje vrijeme udio obnovljivih izvora u strukturi proizvodnih jedinica energetskog sektora u stalnom je porastu. Nepredvidljivost obnovljivih izvora dovodi do poteškoća pri vođenju, planiranju i razvoju elektroenergetskog sustava. Jedan od načina smanjenja negativnog utjecaja nepredvidljivih obnovljivih izvora energije je predviđanje dostupnosti tih izvora. Kratkoročno predviđanje proizvodnje fotonaponskih elektrana jedan je od alata koji to omogućuje. Prikupljanje informacija za model kratkoročnog predviđanja proizvodnje moguće je uzastopnim fotografiranjem polusfere neba iznad fotonaponske elektrane. Obradom podataka sadržanih unutar niza fotografija dolazi se do trenda kojim je moguće predvidjeti buduću proizvodnju fotonaponske elektrane. U ovom radu istražena je nova metoda za kratkoročno predviđanje proizvodnje koja uključuje kontinuirano fotografiranje neba iznad fotonaponske elektrane. Osim nove metode, razvijen je i sustav za prikupljanje i obradu fotografija polusfere neba s ciljem smanjenja troškova integracije takvog sustava. Taj sustav, osim niske cijene, omogućuje i prikupljanje fotografija s visokom frekvencijom uzorkovanja koja je potrebna kako bi se dohvatile informacije o brzim promjenama naoblaka iznad fotonaponske elektrane. Za kratkoročno predviđanje proizvodnje razvijen je i testiran hibridni model koji integrira konvolucijsku neuronsku mrežu i dugotrajnu kratkoročnu memoriju. Ovaj model učinkovito otkriva prostorne i vremenske obrasce iz slika i podataka o izlaznoj snazi, pokazujući značajnu točnost predviđanja. Rezultati razvijenog modela uspoređeni su s modelom trodimenzionalne konvolucijske neuronske mreže trenirane na istim podacima. Ovaj rad ističe potencijal dubokog učenja u poticanju inovacija u sektoru obnovljivih izvora energije, posebno u predviđanju snage pružajući doprinos ukupnoj održivosti elektroenergetskih sustava.

Ključne riječi: obnovljivi izvori energije, kratkoročno predviđanje, fotonaponske elektrane, duboko učenje, analiza fotografije neba

ABSTRACT

Recently, the share of renewable energy sources in the structure of production units of the energy sector has been steadily increasing. The unpredictability of renewable energy sources leads to difficulties in managing, planning and development of the power system. One of the ways to reduce the negative impact of unpredictable renewable energy sources is to predict the availability of these sources. Short-term forecasting of photovoltaic power plant production is one of the tools that make this possible. The information for the short-term production forecast model can be collected by taking successive photographs of the sky hemisphere above the photovoltaic power plant. By processing the data contained in a series of photographs, a trend can be identified that allows the prediction of the future production of the photovoltaic power plant. In this work, a new method for short-term production forecasting was explored that involves continuous photography of the sky above the photovoltaic power plant. In addition to the new method, a system for collecting and processing photographs of the sky hemisphere was developed to reduce the cost of integrating such a system. This system is not only cost-effective, but also enables the collection of photos with a high sampling frequency, which is necessary to capture information about rapid cloud changes over the photovoltaic power plant. A hybrid model integrating convolutional neural networks and long short-term memory was developed and tested for short-term production forecasting. This model effectively reveals spatial and temporal patterns from images and output power data, demonstrating significant prediction accuracy. The results of the developed model were compared with a three-dimensional convolutional neural network model trained on the same data. This work highlights the potential of Deep Learning in driving innovation in renewable energy sector, particularly in power forecasting, contributing to the overall sustainability of electrical power systems.

Keywords: renewable energy sources, short-term forecasting, photovoltaic power plants, deep learning, sky image analysis

SADRŽAJ

1. UVOD	1
1.1. Problem i predmet istraživanja s hipotezom.....	1
1.2. Znanstvena motivacija.....	1
1.3. Svrha i ciljevi istraživanja	3
1.4. Dosadašnja istraživanja u području kratkoročnog predviđanja snage proizvodnje fotonaponskih elektrana	4
1.5. Očekivani znanstveni doprinos istraživanja	10
1.6. Metodologija istraživanja i struktura doktorskog rada	10
2. KRATKOROČNO PREDVIĐANJE SNAGE PROIZVODNJE FOTONAPONSKIH ELEKTRANA.....	13
2.1. Primjena prognoza u upravljanju mrežama s visokim udjelom obnovljivih izvora energije 14	
2.2. Klasifikacija modela za prognozu proizvodnje električne energije iz fotonaponskih sustava na osnovi metode prognoziranja.....	17
2.3. Fizikalne metode.....	18
2.4. Statističke metode.....	19
2.4.1. Izravni i neizravni modeli prognoziranja	20
2.4.2. Klasifikacija predviđanja proizvodnje fotonaponskih elektrana na temelju horizonta prognoziranja.....	21
2.4.3. Probabilističke i determinističke metode prognoziranja	23
2.4.4. Hibridne metode	23
2.5. Prognoziranje proizvodnje fotonaponskih elektrana na razini regije	24
3. SUSTAV ZA PRIKUPLJANJE I OBRADU PODATAKA.....	25
3.1. Tehničke karakteristike sustava.....	26

3.1.1.	Modul kamere	27
3.1.2.	Mini-računalo	28
3.1.3.	Prikupljanje informacija o sunčevom zračenju	30
3.1.4.	Kućište modula.....	31
3.2.	Sastavljanje i montiranje modula za dohvaćanje podataka i kratkoročnu prognozu.....	32
3.3.	Popis komponenti	34
3.4.	Prikupljanje podataka	35
3.5.	Referentna baza podataka.....	38
3.5.1.	Upotreba referentne baze podataka u istraživanju	38
3.5.2.	Objava referentne baze podataka	39
4.	KVANTITATIVNA PROCJENA AMPLITUDNIH VARIJACIJA IZLAZNE SNAGE FOTONAPONSKE ELEKTRANE.....	42
4.1.	Statističke informacije	42
4.2.	Promjena izlazne snage fotonaponskog postrojenja tijekom oblačnog dana	45
5.	MODEL ZA KRATKOROČNU PROGNOZU IZLAZNE SNAGE FOTONAPONSKIH ELEKTRANA.....	53
5.1.	Konvolucijske neuronske mreže.....	54
5.2.	Mreže dugotrajne kratkoročne memorije	55
5.3.	Baze podataka korištene za trening mreže	57
5.3.1.	Višegodišnja baza podataka za trening baznog modela	57
5.3.2.	Specijalizirana baza podataka za fino podešavanje.....	60
5.4.	Strukturiranje i podjela baze podataka	61
5.5.	Mjerenje stvarne izlazne snage promatrane fotonaponske elektrane	62
5.6.	Osnovni dijelovi programskog koda.....	63
5.6.1.	Predobrada podataka	63
5.6.2.	Standardizacija ulaznih fotografija.....	66

5.6.3.	Ekstrakcija značajki kroz konvolucijske slojeve.....	66
5.6.4.	Redukcija dimenzionalnosti kroz sloj grupiranja.....	68
5.6.5.	Poravnavanje podataka i upotreba umjetne neuronske mreže	69
5.6.6.	Primjena metode gašenja pojedinih neurona za izbjegavanje pretreniranosti.....	70
5.6.7.	Izlazni sloj	71
5.7.	Predviđanje trenutne proizvodnje fotonaponske elektrane uporabom fotografija polusfere neba	72
5.7.1.	Konvolucijska neuronska mreža	73
5.7.2.	Ulazni podaci.....	75
5.7.3.	Linearna regresija.....	78
5.7.4.	Višestruka linearna regresija	79
5.7.5.	Obrada fotografija	80
5.7.6.	Model konvolucijske neuronske mreže za predviđanje trenutačne proizvodnje.....	83
5.8.	Rezultati predviđanja trenutne proizvodnje fotonaponskih elektrana	85
5.8.1.	Rezultati regresijske analize.....	86
5.8.2.	Diskusija regresijske analize	91
5.8.3.	Rezultati modela konvolucijske neuronske mreže	94
5.8.4.	Diskusija rezultata modela konvolucijske neuronske mreže.....	96
5.8.5.	Praktična primjena razvijenog modela za predviđanje trenutne proizvodnje fotonaponske elektrane.....	98
5.9.	Predviđanje buduće proizvodnje fotonaponske elektrane uporabom fotografija polusfere neba	99
5.9.1.	Hibridni CNN-LSTM model.....	99
5.9.2.	3D CNN model.....	103
5.10.	Fino podešenje neuronske mreže na specijaliziranoj bazi podataka.....	105
5.11.	Predviđanje buduće proizvodnje fotonaponske elektrane Riteh 1	106

6. REZULTATI PREDVIĐANJA BUDUĆE PROIZVODNJE FOTONAPONSKIH ELEKTRANA.....	108
6.1. Pokazatelji točnosti rezultata	108
6.2. Evaluacija hibridnog CNN-LSTM modela.....	109
6.3. Evaluacija fino podešenog hibridnog CNN-LSTM modela.....	111
6.4. Rezultati predviđanja buduće proizvodnje fotonaponske elektrane Riteh 1	113
6.5. Usporedba s drugim modelima.....	115
6.6. Evaluacija utjecaja duljine ulaznih podataka na kratkoročne predikcije proizvodnje fotonaponskih elektrana	117
6.7. Evaluacija utjecaja vremenske rezolucije ulaznih podataka na točnost modela	120
6.8. Evaluacija utjecaja horizonta prognoze na kratkoročne predikcije proizvodnje fotonaponskih elektrana	122
6.9. Diskusija rezultata modela za predviđanje buduće proizvodnje fotonaponskih elektrana	124
7. ZAKLJUČAK	126
Literatura	128
Popis oznaka i kratica.....	141
Popis slika	143
Popis tablica	147

1. UVOD

1.1. Problem i predmet istraživanja s hipotezom

Negativan utjecaj nepredvidljive krivulje proizvodnje električne energije fotonaponskim sustavima na rad cjelokupnog elektroenergetskog sustava neprestano raste. S porastom udjela obnovljivih izvora u strukturi proizvodnih jedinica energetskega sektora, raste i potreba za naprednijim alatima za prognoziranje koji omogućavaju razumijevanje, predviđanje i upravljanje fotonaponskim sustavima. Prognoziranje proizvodnje fotonaponskih sustava jedna je od tehnologija koja smanjuje negativni utjecaj obnovljivih izvora na mrežu, te tako olakšava njihovu integraciju u elektroenergetski sustav. Kratkoročno prognoziranje očekivane količine proizvedene energije pomaže postojećim metodama planiranja proizvodnje efikasnijim trgovanjem električne energije, upravljanjem elektroenergetskim sustavom i optimiziranim radom spremnicima energije.


U ovom radu opisan je pristup lokalnom prognoziranju izlazne snage fotonaponske elektrane baziran na kratkoročnom predviđanju razine naoblake iznad promatrane elektrane, uporabom širokokutne kamere usmjerene prema nebu.

Uporabom baze podataka s visokom vremenskom rezolucijom moguće je povećati točnost modela za kratkoročno predviđanje proizvodnje fotonaponskih elektrana.

1.2. Znanstvena motivacija

Prirodna tendencija civilizacije prema blagostanju svakog čovjeka, kroz 20. stoljeće ubrzana je industrijskim razvojem. Povećani gospodarski rast usko je povezan s potrošnjom energije [1], što zbog tradicionalnih elektrana na fosilna goriva dovodi do povećanih emisija stakleničkih plinova. Prema izvješću koje je izradilo Međuvladino tijelo za klimatske promjene [2], emisije stakleničkih plinova uzrok su klimatskim promjenama, te ako se ne poduzmu adekvatne mjere, može doći do dodatne štete za ljude i ekosustave. Nakon više od dva desetljeća pregovora, sklopljen je Pariški sporazum [3] kojim se nastoje smanjiti emisije stakleničkih plinova kroz postavljanje ciljeve kao što je ograničavanje porasta globalne prosječne temperature na razinu ispod 2°C u odnosu na razinu u predindustrijskom razdoblju.

Staklenički plinovi iz sektora proizvodnje električne i toplinske energije predstavlja značajan udio u ukupnim emisijama stakleničkih plinova, kao što je vidljivo na slici 1. Kako bi smanjili emisije stakleničkih plinova unutar elektroenergetskog sektora, potrebna je tranzicija na izvore električne energije koje karakteriziraju manje ili zanemarive emisije. Jedne od tih elektrana su elektrane na obnovljive izvore energije [4]. Elektrane na obnovljive izvore energije, kao što su vjetroelektrane i fotonaponske elektrane, ne koriste fosilna goriva kako bi proizvele električnu energiju što znatno smanjuje njihov negativni utjecaj na okoliš.



Slika 1: Emisije stakleničkih plinova u EU po sektoru u 2021. godini [5]

Fotonaponske elektrane (FNE) jedne su od najzastupljenijih elektrana na obnovljive izvore energije [6]. U posljednje vrijeme, zbog njihovog manjeg utjecaja na okoliš, istraživanja su usmjerena na daljnje poboljšanje solarnih ćelija po pitanju njihove učinkovitosti, cijene izrade i dugotrajnosti. Posljedično, zastupljenost FNE u strukturi proizvodnih jedinica energetskog sektora raste [7].

Nepredvidljivost proizvodnje električne energije obnovljivim izvorima pa tako i solarnom energijom, dovodi do varijacija napona i frekvencije unutar elektroenergetskog sustava, a što dovodi do poteškoća u vođenju elektroenergetskog sustava [8]. Promjene u dostupnosti energije obnovljivih izvora događaju se u kratkom razdoblju unutar kojega ostale, tradicionalne elektrane, ne stižu prilagoditi svoju izlaznu snagu. Spor odziv tradicionalnih izvora energije rezultira

gubitkom ravnoteže između proizvedene električne energije i potreba potrošača. U trenutcima u kojima nije zadovoljena ravnoteža između proizvedene i potrošene električne energije dolazi do odstupanja napona i frekvencije od njihovih nazivnih vrijednosti, a što dovodi do smanjenja kvalitete električne energije [9] [10].

Kako bi se negativni utjecaj obnovljivih izvora energije na elektroenergetski sustav smanjio, potrebno je, s određenom točnošću, predvidjeti promjene u dostupnosti tih izvora energije. Velika dinamičnost meteoroloških uvjeta otežava točno dugoročno predviđanje naoblake na određenoj lokaciji [11]. Jedno od rješenja je kratkoročno predviđanje naoblake na gledanoj lokaciji (10 do 15 minuta unaprijed unutar radijusa od 2000 metara). Suženi prostorni i vremenski okviri omogućuju točnije predviđanje naoblake [12]. Primjena pouzdanog sustava za predviđanje proizvodnje električne energije smanjuje potrebu za energijom uravnoteženja, odnosno rezervom snage koja je potrebna za pokrivanje odstupanja proizvodnje obnovljivim izvorima od ugovorenog rasporeda. Tako se, točnijim predviđanjem, smanjuju troškovi integracije obnovljivih izvora energije u elektroenergetski sustav [13]. Također, smanjenje ograničenja proizvodnje energije zbog velike varijabilnosti dovodi do veće iskoristivosti postojećih sustava što, pored smanjenih troškova integracije u sustav, omogućuje niže cijene električne energije za potrošače unutar elektroenergetskog sustava [14].

1.3. Svrha i ciljevi istraživanja

Glavni cilj istraživanja odnosi se na razvoj metode za kratkoročno predviđanje proizvodnje fotonaponskih elektrana uporabom kombinacije konvolucijske neuronske mreže (eng. *convolutional neural network*, CNN) i mreže dugotrajno-kratkoročne memorije (eng. *Long Short-Term Memory*, LSTM). Nova metoda olakšala bi vođenje elektroenergetskog sustava s velikim udjelom fotonaponskih elektrana, te tako ubrzala integraciju obnovljivih izvora u elektroenergetski sustav. Stanica za prikupljanje fotografija neba i informacija o trenutnoj razini sunčeva zračenja omogućuje izradu nove baze podataka visoke prostorne i vremenske rezolucije. Detaljnija baza podataka neophodna je za izradu točnog i pouzdanog modela za predviđanje proizvodnje fotonaponskih elektrana.


1.4. Dosadašnja istraživanja u području kratkoročnog predviđanja snage proizvodnje fotonaponskih elektrana

Velik broj različitih metoda i pristupa prognoziranju proizvodnje FNE razvijen je tijekom godina [15]. Diversifikacija metoda nužna je kako bi se pokrile različite prostorne i vremenske rezolucije, pružajući širi spektar alata za točno i pouzdano predviđanje proizvodnje FNE. Kategorizacija metoda uglavnom se provodi prema vrsti ulaznih podataka, pristupima pretprocesiranju podataka, vremenskoj frekvenciji prikupljanja ulaznih podataka, prostornoj rezoluciji te vremenskom i prostornom horizontu [16].

Jedan od ključnih aspekata prognoziranja proizvodnje fotonaponskih elektrana analiza je vremenskih uvjeta u neposrednoj blizini elektrane. Uvidom u varijacije izlazne snage u odnosu na prikupljene meteorološke parametre moguće je odrediti trendove koji zauzvrat omogućavaju predviđanje buduće proizvodnje. Direktno i difuzno sunčevo zračenje posebno su važni s obzirom na njihov izravan utjecaj na proizvodnju električne energije u fotonaponskim elektranama. S druge strane, parametri poput brzine vjetra, temperature, doba dana i relativne vlažnosti zraka pokazuju znatno nižu korelaciju s proizvodnjom FNE. Takvi su podaci često podložni fluktuacijama zbog različitih uvjeta kao što su promjene smjera i brzine vjetra na različitim visinama od tla i relativna stabilnost temperature u kratkom vremenskom periodu unutar jednog dana [17]. Stoga, ovi parametri često zahtijevaju složenije modele i algoritme za efikasno uključivanje u prediktivne modele.

Kratkoročno predviđanje proizvodnje energije u fotonaponskim elektranama od ključne je važnosti zbog velikih oscilacija koje se mogu javiti u izlaznoj snazi FNE u kratkim vremenskim intervalima. Ove oscilacije često su posljedica promjenjivih vremenskih uvjeta, posebice promjene naoblake [18]. Na primjer, uočeno je da neposredno prije zasjenjenja elektrane oblakom može doći do značajnog povećanja proizvodnje energije. Taj fenomen, poznat kao efekt ruba oblaka, može uzrokovati da izlazna snaga FNE privremeno dostigne vrijednosti do 150% zadnje stabilne vrijednosti snage. Ovo je rezultat superpozicije direktnog sunčevog zračenja i zračenja raspršenog od obližnjeg oblaka [19]. Stoga, sposobnost predviđanja takvih oscilacija omogućuje sustavu da se pravovremeno pripremi za potencijalne fluktuacije u proizvodnji.

Na slici 2 prikazana je snaga fotonaponske elektrane Riteh 1 smještene pokraj Tehničkog fakulteta, Sveučilišta u Rijeci. Efekt ruba oblaka vidljiv je tijekom oblačnih dana: izlazna snaga fotonaponske elektrane doseže značajno veće vrijednosti u usporedbi s istim dobom dana u uvjetima bez naoblake.



Slika 2: Snaga fotonaponske elektrane Riteh 1

Važnost kratkoročne prognoze solarne iradijacije nije zanemariva kada se radi o predviđanju izlazne snage fotonaponskih elektrana. Složenost ovog zadatka leži u inherentnoj nasumičnosti i nelinearnosti solarne iradijacije, što se posebno ističe pod promjenjivim vremenskim uvjetima. Mnogi znanstveni radovi istaknuli su primjenu umjetnih neuronskih mreža (eng. *artificial neural network*, ANN) za ovakve modele prognoza zbog njihove sposobnosti prilagodbe kompleksnim i nelinearnim obrascima [20] [21]. Unatoč tome, potrebno je dodatno usavršavanje u pogledu sažetosti i robusnosti ovih modela [22].

Kompleksnost vremenskih uvjeta uzrokuje nepredvidljivo i nestabilno ponašanje fotonaponskih sustava, što znatno otežava precizno predviđanje proizvodnje. Rekurentne neuronske mreže (eng. *recurrent neural network*, RNN) tradicionalno se koriste za predviđanje vremenskih nizova, ali intenzivne promjene vremenskih uvjeta mogu uzrokovati pogreške tijekom njihovog treninga, posebice kada se koriste dugoročni nizovi ulaznih podataka. Kako bi se ovaj problem riješio, koristi se struktura duboke rekurentne neuronske mreže poznate kao mreže dugotrajne kratkoročne

memorije (eng. *long short-term memory*, LSTM). Ova struktura, zahvaljujući svojim specifičnim skrivenim jedinicama, može očuvati informacije o trendovima sadržanim u dugoročnim sekvencama, čime se poboljšavaju performanse i rješava problem koji RNN ima s dugoročnim zavisnostima. U kontekstu kratkoročnih prognoza, LSTM pristup se koristi sa specifičnim vremenskim skalama koje se odnose na globalnu horizontalnu iradijaciju (eng. *global horizontal irradiance*, GHI) za predviđanje jedan sat unaprijed, kao i jedan dan unaprijed. Za ovakve modele dostupnost sunčevog zračenja za određenu lokaciju predstavlja ključan ulazni podatak [23]. Najveće nepreciznosti u predviđanjima obično se javljaju tijekom oblačnih dana. Kako bi se poboljšala točnost predviđanja za ovakve dane, uvodi se indeks naoblake kao ulazni podatak za LSTM model. Ovaj indeks koristi se za klasifikaciju vremenskih uvjeta tijekom obrade podataka, gdje se oblačni dani kategoriziraju kao oblačni i djelomično oblačni [24].

Prognoze izlazne snage fotonaponskih elektrana mogu se temeljiti na različitim izvorima podataka, uključujući i satelitske snimke. Tradicionalno, model vektora kretanja oblaka (eng. *cloud motion vector*, CMV) koristi se kao vodeći model za prognozu solarne proizvodnje temeljen na satelitskim slikama. No, ovaj model ima ograničenja - pretpostavlja konstantne oblike oblaka, a njegova točnost može biti narušena promjenjivim lokalnim vremenskim karakteristikama [25].


Za utvrđivanje trendova promjena naoblake potrebni su precizni ulazni podaci koji uključuju trenutno i prethodno stanje naoblake iznad promatrane FNE. Količina naoblake, pozicija te smjer i brzina kretanja oblaka mogu se, kao što je navedeno, odrediti analizom satelitskih i radarskih snimaka naoblake [26]. Međutim, postojeće baze podataka koje se temelje na satelitskim snimkama često nisu adekvatne za uporabu u kratkoročnoj prognozi. Razlog tome je nedostatna vremenska i prostorna rezolucija ovih podataka [27]. Za efikasnu lokalnu, kratkoročnu prognozu potrebna je baza podataka koja sadrži visoko detaljne informacije o naoblaci iznad elektrane, a koje su prikupljene s visokom vremenskom i prostornom rezolucijom. Jedan od načina za generiranje takvih baza podataka je uzastopno fotografiranje polusfere neba iznad lokacije elektrane [28]. Trenutno, rješenja koja koriste ovaj pristup nisu široko rasprostranjena, uglavnom zbog visoke cijene opreme potrebne za prikupljanje fotografija. Smanjenje cijene ove opreme moglo bi potaknuti njenu širu uporabu, a što bi rezultiralo većim i raznolikijim bazama podataka koje bi se mogle koristiti za razvoj novih modela za predviđanje proizvodnje FNE [29].

Za uspješno predviđanje proizvodnje fotonaponske elektrane na temelju niza fotografija polusfere neba, ključno je identificirati korelaciju između informacija sadržanih unutar tih fotografija i količine sunčevog zračenja koje doseže mjesto elektrane. Ove su korelacije iznimno važne jer je količina sunčevog zračenja na lokaciji fotonaponske elektrane direktno povezana s trenutnom snagom proizvodnje te elektrane [30].

Pored informacija sadržanih unutar fotografija, moguće je koristiti i druge parametre koji mogu utjecati na procjenu sunčevog zračenja i na proizvodnju elektrane. Ti parametri uključuju temperaturu, relativnu vlažnost i tlak zraka, brzinu i smjer vjetra. Ove veličine mogu se izmjeriti pomoću relativno jeftine meteorološke stanice [31].

Detaljna analiza utjecaja pojedinih parametara kao što su temperatura, temperatura točke rosišta, relativna vlažnost zraka, vidljivost, tlak zraka, brzina vjetra, naoblaka, smjer vjetra i količina oborina, na izlaznu snagu elektrane pokazuje da svaka od tih veličina samostalno ima relativno nisku korelaciju s izlaznom snagom. Međutim, analizom kombiniranog utjecaja više parametara moguće je postići veću korelaciju [32]. Korištenje samo jednog ulaznog podatka, poput fotografije neba, za procjenu trenutne i buduće proizvodnje znatno pojednostavljuje sustav, čineći ga robusnijim, jednostavnijim za implementaciju i ekonomski isplativijim [33]. Iako je moguće provesti istraživanje koristeći više ulaznih parametara uz sliku kako bi se postigla veća korelacija, takav pristup može znatno zakomplicirati prikupljanje i obradu podataka, kao i sam sustav za kratkoročno predviđanje proizvodnje fotonaponske elektrane.

Različite metode obrade fotografija polusfere neba omogućavaju daljnju preciznost u predviđanju proizvodnje fotonaponske elektrane. Primjerice, vektori kretanja oblaka koji se određuju iz niza fotografija mogu bitno unaprijediti točnost predviđanja proizvodnje fotonaponskih sustava [34]. Određivanje lokacije oblaka na osnovu niza fotografija i usporedba njegove pozicije na dvije uzastopne fotografije, omogućuje izračun vektora kretanja oblaka kao što je vidljivo na slici 3. Kombinacijom informacija o veličini oblaka te njegovoj brzini i smjeru kretanja, moguće je procijeniti vjerojatnost budućeg zasjenjenja fotonaponske elektrane, a time i predvidjeti buduću proizvodnju električne energije na tom mjestu [35].




Slika 3: Metoda vektora kretanja oblaka

Konvolucijske neuronske mreže posebno su pogodne za detekciju nelinearnih odnosa između ulaznih i izlaznih podataka modela za kratkoročno predviđanje proizvodnje fotonaponskih elektrana. Ove mreže mogu prepoznati uzorke unutar fotografija, a što im omogućuje korištenje tih fotografija kao ulaznih podataka. S obzirom na to da su fotografije neba iznad fotonaponske elektrane direktno korelirane s njenom izlaznom snagom [36], konvolucijske neuronske mreže mogu koristiti te fotografije kako bi otkrile korelacije između fotografija neba i izlazne snage FNE.

Upotrebom postojećih algoritama za predviđanje budućih fotografija u nizu [37], moguće je razviti model kratkoročne prognoze proizvodnje fotonaponske elektrane. Takav model, koristeći predviđanja budućih razina naoblake, temeljem trendova kretanja oblaka i promjena u svjetlosti fotografija, može precizno predviđati buduću proizvodnju FNE [38].

Pregledom dostupnih baza podataka uočava se nedostatak detaljnih baza koje uključuju fotografije neba uz prateće podatke o sunčevom zračenju s visokom rezolucijom uzorkovanja [39]. Baze podataka s niskom rezolucijom prikupljanja fotografija i podataka o sunčevom zračenju ne mogu adekvatno uhvatiti iznenadne promjene u izlaznoj snazi fotonaponske elektrane koje su često uzrokovane zasjenjenjem oblaka. Na slici 4 vidljivo je da, kada se podaci o proizvodnji fotonaponske elektrane prikupljaju s manjom vremenskom rezolucijom, dolazi do gubitka značajne količine informacija o promjenama izlazne snage uzrokovanih promjenama naoblake.

Baza podataka koja sadrži stvarne podatke o izlaznoj snazi fotonaponske elektrane trebala bi imati relativno visoku vremensku rezoluciju kako bi mogla obuhvatiti nagle promjene u izlaznoj snazi te elektrane. Ova potreba posebno je naglašena zbog izrazito dinamične prirode vremenskih uvjeta na lokacijama elektrana, što je uzrokovano velikom brzinom kretanja oblaka s relativno malim volumenom.



Slika 4: Utjecaj vremenske rezolucije dohvaćanja podataka na točnost baze podataka [40]. Usporedba podataka dobivenih s 45 sekundnim i 5 minutnim intervalom. Prikaz dva karakteristična dana; a) djelomično oblačan dan, b) oblačan dan

Na temelju pregleda dostupnih metoda, uporaba konvolucijske neuronske mreže u kombinaciji s mrežom dugotrajne kratkoročne memorije pokazuje najveći potencijal za kratkoročno predviđanje proizvodnje fotonaponske elektrane. Međutim, točnost modela generiranog konvolucijskom neuronskom mrežom ovisi o kvaliteti ulaznih podataka. Ovo ukazuje na važnost postojanja detaljne i sveobuhvatne baze podataka koja bi omogućila bolje treniranje neuronske mreže i stoga preciznije predviđanje proizvodnje fotonaponske elektrane.

1.5. Očekivani znanstveni doprinos istraživanja

Glavni doprinosi ovog rada uključuju razvoj hibridnog CNN-LSTM modela neuronske mreže koji koristi fotografije neba niske rezolucije i podatke o izlaznoj snazi fotonaponskih elektrana kao ulazne podatke. Ovaj model dizajniran je za predviđanje proizvodnje elektrane 15 minuta unaprijed. Drugi doprinos je izrada modula za izradu baze podataka. Referentna baza podataka fotografija polusfere neba i popratnih meteoroloških uvjeta pruža mogućnost izrade i usporedbe različitih modela neuronskih mreža treniranih na istim ulaznim podacima. Treći doprinos kreiranje je testnog poligona za verifikaciju i evaluaciju točnosti predviđanja predloženog modela te usporedbu s drugim modelima. Ovaj poligon sastoji se od fotonaponske elektrane Riteh 1 i modula za kratkoročno predviđanje proizvodnje fotonaponske elektrane. Modul je opremljen malom kamerom za dohvaćanje fotografija polusfere neba i malim solarnim panelom za indirektno mjerenje dostupnog sunčevog zračenja.

Znanstveni doprinosi:

1. Model za kratkoročno predviđanje proizvodnje fotonaponskih elektrana uporabom konvolucijske neuronske mreže trenirane sukcesivnim nizom fotografija polusfere neba
2. Referentna baza podataka fotografija polusfere neba i popratnih meteoroloških uvjeta
3. Testni poligon za verifikaciju i evaluaciju točnosti predviđanja predloženog modela te usporedbu s drugim modelima

1.6. Metodologija istraživanja i struktura doktorskog rada

Provedeno istraživanje obuhvaća cjelokupan razvoj modela za kratkoročno predviđanje proizvodnje fotonaponskih elektrana. Prvi dio prikazuje utjecaj ulaznih podataka na sposobnost detekcije naglih promjena u izlaznoj snazi fotonaponske elektrane. Drugi dio rada odnosi se na razvoj i testiranje modela za predviđanje proizvodnje fotonaponske elektrane pomoću fotografija

polusfere neba. U drugom dijelu, razvijen je i hibridni model koji služi kao ključna komponenta u ostvarivanju tog cilja.

Hibridni model za kratkoročno predviđanje proizvodnje fotonaponskih elektrana kombinira konvolucijsku neuronsku mrežu (CNN) i model kratkoročne dugoročne memorije (LSTM). Ovaj model koristi niz fotografija polusfere neba i pripadajuće podatke o proizvodnji elektrane i generira predviđanja za buduću proizvodnju na temelju tih podataka. Konvolucijska neuronska mreža koristi se za detekciju uzoraka u ulaznim fotografijama, dok se model dugoročne memorije koristi za obradu vremenskih serija podataka.

Rezultati dobiveni hibridnim CNN-LSTM modelom uspoređeni su s drugim modelom koji je također treniran na istim ulaznim podacima. Taj je drugi model trodimenzionalna konvolucijska neuronska mreža (3D CNN) koja koristi volumetrijske podatke o fotografijama neba za predviđanje buduće proizvodnje.

Razvijeni model inicijalno je treniran na velikoj bazi podataka, a zatim je fino podešen s novom bazom podataka. Ova nova baza, sačinjena od fotografija i informacija o sunčevom zračenju na lokaciji stvarne fotonaponske elektrane, kreirana je kako bi se predvidjela buduća proizvodnja te elektrane. Fino podešavanje modela omogućuje prilagodbu postojećeg modela novim uvjetima. Konačno, točnost predviđanja hibridnog modela verificirana je i evaluirana na testnom poligonu koji se sastoji od stvarne fotonaponske elektrane i sustava za kratkoročnu prognozu.

Doktorski rad sastoji se od sedam poglavlja, pri čemu svako poglavlje samostalno razrađuje ključne aspekte istraživačkog rada.

U prvom poglavlju doktorskog rada iznosi se problem i predmet istraživanja, znanstvena motivacija, svrha i ciljevi istraživanja, dosadašnja istraživanja u području kratkoročnog predviđanja snage proizvodnje fotonaponskih elektrana, očekivani znanstveni doprinos, metodologija znanstvenog istraživanja i struktura doktorskog rada.

U drugom poglavlju sagledana je primjena prognoze proizvodnje fotonaponskih elektrana. Također je predstavljen pregled i klasifikacija metoda za predviđanje proizvodnje.

U trećem poglavlju detaljno je opisan sustav za prikupljanje i obradu podataka. Navedene su tehničke karakteristike razvijenog modula i opisani njegovi dijelovi.

U četvrtom poglavlju provedena je procjena izlazne snage fotonaponske elektrane. Procjena je provedena u svrhu analize utjecaja frekvencije dohvaćanja ulaznih podataka na gubitak informacija o stvarnoj proizvodnji fotonaponske elektrane.

U petom poglavlju razvijen je model za kratkoročnu prognozu izlazne snage fotonaponske elektrane. Detaljno je opisana baza podataka koja je korištena za trening modela. Nakon toga opisani su glavni dijelovi modela i dijelovi programskog koda kojim je kreiran model. Kao prvi korak prema kratkoročnoj prognozi, kreiran je model za predviđanje trenutne proizvodnje. Temeljen na tom modelu, dodatkom mogućnosti analize u vremenskoj domeni, kreiran je i model za kratkoročnu prognozu izlazne snage fotonaponske elektrane.

U šestom poglavlju prikazani su rezultati evaluacije modela. Model je evaluiran i prikazani su rezultati predviđanja proizvodnje za nekoliko dana. Potom su rezultati predviđanja modela uspoređeni s drugim modelom, a analizira se i utjecaj duljine ulaznih podataka i horizonta predviđanja na točnost kratkoročne prognoze modela.

Sedmo poglavlje sadrži zaključak provedenog istraživanja. Poglavlje istražuje i različite scenarije i kontekste u kojima bi implementacija ovakvog sustava mogla biti korisna. Osim toga, nudi se sveobuhvatni pregled potencijalnih mogućnosti za daljnja unapređenja i optimizacije sustava.

2. KRATKOROČNO PREDVIĐANJE SNAGE PROIZVODNJE FOTONAPONSKIH ELEKTRANA

Negativan utjecaj tradicionalnih izvora energije na klimu doveo je do povećane integracije obnovljivih izvora energije (OIE) u elektroenergetsku mrežu. Povećan udio OIE sa sobom donosi i veću nepredvidivost dostupne proizvodne snage. Ta povećanja dovode do ovisnosti dostupne energije o trenutnim vremenskim uvjetima, a što rezultira povećanjem nesigurnosti kada je u pitanju proizvodnja električne energije. Potrošnja energije u mreži također je ovisna o vremenskim uvjetima, ne samo zbog promjene u energiji potrebnoj za grijanje i hlađenje, nego i zbog promjena u lokalnoj proizvodnji električne energije malim fotonaponskim elektranama na strani potrošača.

Kako bi se kompenzirale promjene u potrošnji električne energije, struktura proizvodnih jedinica energetskog sektora mora sadržavati upravljive izvore energije kao što su tehnologije ovisne o uporabi goriva i hidroelektrane. Kod takvih elektrana moguće je upravljanje uporabe resursa za proizvodnju energije, ali i spremanje energije u obliku potencijalne energije vode primjenom akumulacijskih jezera ili spremnika goriva kod termoelektrana. Obnovljivi izvori energije ne pružaju mogućnost kontrole dostupnosti pa tako i skladištenja, te se zbog toga koriste metode upravljanja izlazne snage elektrana. Jedan od načina upravljanja ograničenje je proizvodnje energije. Reduciranom pretvorbom dostupne obnovljive energije u električnu energiju smanjuje se izlazna snaga. Alternativa ograničavanju proizvodnje električne energije je prognoza dostupnosti obnovljivih izvora te priprema mreže na nadolazeće promjene u proizvodnji [41]. Pri smanjenju nepredvidljivosti obnovljivih izvora energije, prognoza proizvodnje postaje jedan od ključnih elemenata u vođenju elektroenergetskog sustava. Prognoze proizvodnje koriste se u planiranju i korištenju spremnika energije u mreži, pri izradi pogonskih karata, na tržištu električne energije, u upravljanju zagušenjima itd.

Fotonaponski sustav može raditi u otočnom načinu rada ili može biti povezan s ostatkom elektroenergetske mreže. Sustavi koji rade u otočnom pogonu se obično sastoje od izvora električne energije (fotonaponski paneli), baterijskog spremnika energije, izmjenjivača i lokalnih potrošača. Međutim, većina današnjih fotonaponskih sustava povezana je s mrežom te se sastoji samo od fotonaponskih panela i mrežnih izmjenjivača. Mrežno vezani sustavi sa sobom donose promjene u

cijelom sustavu koje mogu biti pozitivne i negativne. Jedan od primjera pozitivne promjene je smanjenje opterećenja prijenosnih vodova u slučaju lokalne proizvodnje, dok negativne promjene mogu biti neželjene oscilacije u naponu i frekvenciji [42].

Brz porast udjela solarne energije u strukturi proizvodnih jedinica energetskog sektora zabilježen je u ruralnim i gradskim područjima diljem svijeta (primjerice u Švedskoj, Njemačkoj, Indiji i nekim dijelovima Afrike) [43]. Proizvedena energija koristi se lokalno, ali i u prijenosnoj i distribucijskoj mreži. U regijama s povećanim udjelom obnovljivih izvora energije opaženo je poboljšanje stanja mreže smanjenim opterećenjem prijenosnih vodova, ali i negativan utjecaj po pitanju vođenja elektroenergetskog sustava. Nepredvidivost obnovljivih izvora može imati utjecaj na razinu i stabilnost napona i frekvencije, pa tako i na zaštitu prijenosne i distribucijske mreže [44].

Brojna istraživanja usmjerena su na razvijanje optimalnih modela za prognozu koji precizno predviđaju proizvodnju električne energije iz fotonaponskih (FN) sustava. Smanjenje kompleksnosti modela i troškova povezanih s njihovom izradom i implementacijom jedan je od ključnih ciljeva ovih istraživanja. Proces prognoze proizvodnje u fotonaponskim elektranama obično se sastoji od tri ključna koraka. Početni korak obuhvaća identifikaciju i odabir ključnih aspekata ili varijabli koje su relevantne za proizvodnju fotonaponskog sustava. Primjerice, faktore poput razine sunčeve svjetlosti, vremenskih uvjeta, učinkovitosti fotonaponskih panela itd. Prvi korak obuhvaća i analizu čimbenika koji utječu na te faktore, primjerice za razinu sunčeve svjetlosti važni su čimbenici kao što su doba dana, godišnje doba, vremenski uvjeti, geografska lokacija i slično. U drugom koraku odabire se odgovarajuća metoda predviđanja i optimizira se model prognoze. Treći je korak implementacija modela [45].

2.1. Primjena prognoza u upravljanju mrežama s visokim udjelom obnovljivih izvora energije

Obnovljivi izvori energije doživljavaju eksponencijalni rast u elektroenergetskim mrežama diljem svijeta te sa sobom donose nove izazove operatorima prijenosnog sustava. Ti su izazovi

karakterizirani povećanjem nestabilnosti i promjenjivosti na više vremenskih skala, od tjedana, dana, sata, sve do minuta i sekundi. Istraživanja vezana uz kratkoročno predviđanje proizvodnje fotonaponskih elektrana temelje se na vremenskim periodima kraćim od jednog dana. U sklopu ovog rada analiziraju se promjene na razini 15 minuta.

Promjene i nepredvidljivost proizvodnje fotonaponskih sustava pojavljuju se u različitim vremenskim okvirima. Izlazna snaga mijenja se na dnevnoj, satnoj, minutnoj, pa čak i sekundnoj razini. U svim navedenim vremenskim okvirima otežano je predviđanje proizvodnje. Svaki različiti vremenski okvir predviđanja proizvodnje sa sobom donosi i poteškoće u predviđanju. Zbog toga je potrebno provesti analizu utjecaja obnovljivih izvora na mrežu, uzimajući u obzir različite vremenske okvire povezane s različitim klimatskim uvjetima.

Prognoza nije nov pojam unutar elektroenergetskog sustava i predstavlja ključnu komponentu modernog sustava upravljanja, pogotovo u mrežama s velikim udjelom obnovljivih izvora energije.

Većina istraživanja vezanih za prognozu u kontekstu vođenja, planiranja i rada elektroenergetskog sustava usmjerila se na četiri ključne varijable: potražnja za električnom energijom [46], cijena električne energije [47], energija vjetra [48] i sunčeva energija [49]. Ove četiri veličine postaju veoma važne opskrbljivačima električne energije te operatorima prijenosnog sustava.

Za operatora prijenosnog sustava poznavanje potražnje za električnom energijom neophodno je za planiranje rada elektroenergetskog sustava, upravljanje preopterećenjima, kupovinu rezervi i osiguranje minimalnih troškova, pod uvjetom da je osigurana opskrba električnom energijom. Sukladno tome, operator prijenosnog sustava može profitirati od prognoziranja krivulje opterećenja kako bi optimizirao operativno vođenje mreže te upravljanje energetske spremnicima spojenim na mrežu. Kratkoročno predviđanje može unaprijediti postojeće metode prognoziranja uvodeći veću vremensku i prostornu rezoluciju.

S većim udjelom obnovljivih izvora energije u mreži, stabilnost cijena električne energije opada. Korištenjem sustava za kratkoročno predviđanje proizvodnje fotonaponskih elektrana, moguće je ostvariti ekonomsku dobit koja opravdava njegovu instalaciju. Dobit se ostvaruje kroz povećanje zarade u trgovanju električnom energijom, bolje upravljanje spremnicima energije i planiranje proizvodnje.

U Europskoj uniji, vjetroelektrane i solarne elektrane zauzimaju drugo i treće mjesto po udjelu u obnovljivim izvorima energije. Na prvom mjestu su hidroelektrane koje imaju relativno stabilnu, i u slučaju akumulacijskih hidroelektrana, kontroliranu izlaznu snagu.

Lokalna upotreba fotonaponskih elektrana dovodi do nestabilnosti krivulje opterećenja, što smanjuje mogućnosti njenog prognoziranja. Međutim, sustav kratkoročnog prognoziranja koji koristi fotografije neba može se koristiti kako bi se predvidjelo kretanje oblaka iznad određene površine, primjerice grada. Takav sustav bi mogao predvidjeti kratkoročne promjene u proizvodnji lokaliziranih elektrana uzrokovane promjenama u naoblaci, čime bi se olakšalo kratkoročno predviđanje krivulje opterećenja.

Cijena električne energije važan je parametar za sve sudionike tržišta električne energije i motiv za većinu njihovih aktivnosti. Prognoza cijena neizostavna je na današnjim tržištima električne energije i ključan je ulazni podatak za sudionike na tržištu. Tvrtke koje trguju na tržištima električne energije često se koriste metodama predviđanja cijena kako bi se informirale o stanju tržišta. Međutim, unatoč važnosti predviđanja cijene električne energije, radi se o složenom sustavu što prognoziranje čini otežanim.

Stabilnost frekvencije unutar elektroenergetskog sustava zahtijeva konstantnu ravnotežu između proizvodnje i potrošnje električne energije. U kratkim vremenskim razdobljima, većina korisnika električne energije nije svjesna njezine cijene. Štoviše, u kratkom vremenskom razdoblju preopterećenja u prijenosu mogu spriječiti slobodnu razmjenu između različitih regija. Ove činjenice dovode do ekstremnih fluktuacija cijena ili čak skokova cijena na tržištu električne energije. Uz to, nestabilnost cijene goriva, neizvjesnost opterećenja, promjene u proizvodnji električne energije iz hidroelektrana, nesigurnost proizvodnje (ispadi) i ponašanje tržišta također doprinose nestabilnosti cijene električne energije [41].


Cijena električne energije često postiže ekstremne vrijednosti koje se rijetko viđaju na financijskim tržištima. Nesigurnost satnih opterećenja i neki drugi stohastički uzroci, kao što su kvarovi opreme i cijena goriva, u kombinaciji rezultiraju višom razinom nestabilnosti u cijeni električne energije [50]. Dodatno, cijena električne energije je nelinearna funkcija koja sadrži više vremenskih varijanti svojih ulaznih značajki koje se nelinearno mijenjaju s obzirom na varijacije ulaznih parametara. Na primjer, opterećenje je važan pokretač cijene električne energije. Međutim,

varijacije opterećenja u razinama niskog i visokog opterećenja imaju različite utjecaje na cijenu električne energije. Štoviše, njihova vremenski varijabilna priroda povezana je, na primjer, s diskretnim promjenama sudionika, strategija (npr. agenti se odluče prebaciti s konzervativnog ponašanja na agresivnije ili rizičnije) ili s promjenama u tržišnim regulativama. Rasprava o drugim karakteristikama cijene električne energije kao što su višestruka sezonalnost (npr. dnevne i tjedne periodičnosti), visokofrekventne promjene i visoki postoci neuobičajenih cijena može se pronaći u literaturi [50].

Iz navedenog je vidljivo da je precizna prognoza proizvodnje fotonaponskih sustava ključna, ne samo za opskrbljivače električnom energijom, nego i za operatore prijenosnog i distribucijskog sustava. Operatorima prijenosnog i distribucijskog sustava potrebna je točna prognoza kako bi mogli kupovati rezerve i predviđati moguća preopterećenja, dok opskrbljivači koriste prognoze za učinkovito trgovanje i planiranje proizvodnje.

2.2. Klasifikacija modela za prognozu proizvodnje električne energije iz fotonaponskih sustava na osnovi metode prognoziranja

Strategije za prognozu proizvodnje u fotonaponskim elektranama mogu se sustavno klasificirati u tri osnovne kategorije; fizikalne, statističke i hibridne metode prognoziranja. Ove opće kategorije mogu se dodatno razdijeliti temeljem konkretnih postupaka modeliranja koji se koriste u različitim studijama i znanstvenoj literaturi (kao što je prikazano na slici 5).



Slika 5: Klasifikacija metoda za prognoziranje proizvodnje fotonaponskih elektrana

Unutar svake od ovih kategorija, metode se razlikuju prema načinu prikupljanja i obrade podataka, što može biti temeljeno na fizikalnim zakonima, statističkim analizama ili kombinaciji. Naposljetku, važno je napomenuti da učinkovitost svakog modela u velikoj mjeri ovisi o specifičnim uvjetima pod kojima se koristi, uključujući geografsku lokaciju, vremenske uvjete i vrstu fotonaponskog sustava. Unatoč postojanju širokog spektra modela, svaki od njih ima svoje jedinstvene prednosti i ograničenja, što ih čini pogodnima za određene primjene, ali ne nužno i za sve.

2.3. Fizikalne metode

Fizikalna metoda predviđanja proizvodnje električne energije temelji se na simulaciji procesa pretvorbe sunčeve svjetlosti u električnu energiju te simulaciji okoline elektrane koja može utjecati na njenu izlaznu snagu. Ovaj pristup koristi različite fizikalne parametre povezane s vremenskim uvjetima, uključujući pokrivenost neba oblacima, temperaturu okoline, intenzitet sunčevog zračenja, relativnu vlažnost zraka, točku rosišta te brzinu i smjer vjetra. Ovi se parametri koriste kao ulazni vektori u fizikalnim jednadžbama koje procjenjuju izlaznu snagu fotonaponskih elektrana.

Konstrukcija fizikalnih modela zahtijeva informacije o specifičnoj lokaciji, vremenskim parametrima, orijentaciji fotonaponskih panela, kao i povijesne podatke o proizvodnji električne energije. Modeli koji se razvijaju korištenjem ove metode obično su jednostavni kada se koristi samo globalno sunčevo zračenje. Međutim, dodavanjem dodatnih vremenskih parametara poput naoblake ili temperature okoline, složenost modela može se povećati [51].

Ova metoda nije prikladna za prognozu naglih, značajnih promjena u vremenskim uvjetima. Iz tog su razloga fizikalni modeli pokazuju veću preciznost pod stabilnim vremenskim uvjetima.

Primjeri implementacije fizikalne metode uključuju numeričke modele prognoze vremena (eng. *Numerical weather prediction*) [52], analizu fotografija polusfere neba (eng. *total sky imagers*) [53] i korištenje satelitskih slika [54]. Ovi alati omogućuju precizniju i učinkovitiju implementaciju fizikalnog pristupa u stvarnom vremenu te pružaju osnovu za daljnja poboljšanja i optimizaciju prognostičkih metoda.

2.4. Statističke metode

Statističke metode izgrađene su na temelju obrazaca promjena u proizvodnji ili slučajnih vremenskih nizova. Izgradnja modela za predviđanje proizvodnje fotonaponskih elektrana provodi se utvrđivanjem veza između ulaznih varijabli (vektora) i odgovarajućeg energetskog izlaza putem verificiranih standardnih i znanstvenih metoda.

Vremenski parametri koji utječu na proizvodnju fotonaponskih elektrana, poput naoblake, temperature, padalina, brzine vjetra, relativne vlažnosti, temperature fotonaponskih modula i drugih, koriste se kao ulazni podaci za algoritme prognoze. U ovom kontekstu, oni se nazivaju ulazne varijable ili vektori.

Metode korištene u ovoj kategoriji uključuju tradicionalnu statističku analizu, umjetnu inteligenciju (eng. *artificial intelligence*) i metode strojnog učenja (eng. *machine learning*). Tradicionalni pristupi predviđanja [55] primjenjuju tehnike regresijske analize na vremenske nizove podataka za generiranje modela koji predviđaju proizvodnju fotonaponskih elektrana.

Primjeri tehnika prognoziranja koji koriste umjetnu inteligenciju uključuju umjetne neuronske mreže (eng. *artificial neural network*) [56], slučajne šume (eng. *random forest feature selection*) [57] i mreže dugotrajne kratkoročne memorije (eng. *long short term memory*, LSTM) [24]. Važno je istaknuti da se koriste različite izvedbe navedenih tehnika.

Napredak u mjernim metodama omogućio je generiranje velike količine podataka prikupljene tijekom dužeg vremenskog perioda, što je omogućilo paralelni napredak u tehnologijama primjena metoda koje koriste te podatke. U nastavku su prikazane i detaljno analizirane neke od statističkih metoda prognoziranja prikazanih na slici 5.

2.4.1. Izravni i neizravni modeli prognoziranja

Izravni modeli predviđanja koriste povijesne podatke o proizvodnji fotonaponskih elektrana za generiranje prognoza [58]. Oni nastoje identificirati vezu između ulaznih varijabli i proizvodnje fotonaponskih elektrana analizirajući povijesne podatke.

S druge strane, neizravne tehnike predviđanja provode se u dvije faze [59]. U prvom koraku, modeliraju se vremenski čimbenici koji utječu na proizvodnju fotonaponskih elektrana, poput sunčevog zračenja. Drugi korak pretvara rezultate prvog koraka u prognozu proizvodnje fotonaponskih elektrana [60].

Primarna razlika između ove dvije metode je ta da izravna metoda ne zahtijeva izračunavanje vrijednosti sunčevog zračenja u međufazi. Metode temeljene na fotografijama [61], meteorološke numeričke prognoze [62], umjetne neuronske mreže [20] i hibridne metode [51] koriste neizravne metode predviđanja na različitim vremenskim skalama za prognozu proizvodnje fotonaponskih elektrana.

Različiti komercijalni softveri za simulaciju proizvodnje fotonaponskih elektrana, kao što su PVsyst [63], PVWatts [64], PVGIS [65], PVSol [66], Helioscope [67] i RETScreen [68] koriste ove metode za prognozu proizvodnje fotonaponskih elektrana. Ti softveri koriste prognozirano sunčevo zračenje i povezane vremenske podatke kao ulazne podatke za svoje prognoze.

Pregled implementacije izravne i neizravne metode za prognoziranje proizvodnje fotonaponskih elektrana za sljedeći dan [69] daje uvid da izravna metoda pruža bolje rezultate. Neizravne metode pružaju preciznije prognoze za period od jednog dana jer uzimaju u obzir faktore specifične za određenu lokaciju, kao što su utjecaji naoblake, temperature i geografske pozicije, prije nego što predvide izlaznu snagu fotonaponske elektrane.

2.4.2. Klasifikacija predviđanja proizvodnje fotonaponskih elektrana na temelju horizonta prognoziranja

Horizont predviđanja odnosi se na vremenski period u budućnosti za koji se izrađuje predviđanje proizvodnje fotonaponskih elektrana. Točnost predviđanja modela varira s promjenom horizonta predviđanja kada svi ostali parametri modela ostaju nepromijenjeni. Zbog toga je važno uzeti u obzir horizont predviđanja pri izradi modela.

Na temelju horizonta predviđanja, predviđanje proizvodnje fotonaponskih elektrana može se podijeliti u četiri skupine; vrlo kratkoročno, kratkoročno, srednjoročno i dugoročno predviđanje. Vrlo kratkoročno predviđanje odnosi se na horizont predviđanja od nekoliko sekundi do jedne minute, ali manje od jednog sata. Kratkoročno predviđanje odnosi se na razdoblje od jednog do nekoliko dana. Ovo predviđanje omogućuje planiranje angažmana proizvodnih jedinica, a također poboljšava sigurnost rada elektroenergetskog sustava. Nadalje, kratkoročno predviđanje obično se koristi za svakodnevno trgovanje električnom energijom. Srednjoročno predviđanje se provodi za razdoblje od tjedan do mjesec dana. Ova kategorija predviđanjem buduće dostupnosti energije olakšava planiranje razvoja elektroenergetskog sustava te održavanje. Kada je horizont predviđanja fotonaponskih elektrana u razdoblju od mjesec do godine dana, to se smatra dugoročnim predviđanjem. Ova kategorija je ključna za planiranje proizvodnje električne energije te razvoj prijenosne i distribucijske mreže.

Tablica 1 sažima klasifikaciju predviđanja proizvodnje fotonaponskih elektrana na temelju horizonta predviđanja. Iako se horizont predviđanja nalazi pod klasom statističke metode, svaka

metoda predviđanja koja se koristi za predviđanje proizvodnje fotonaponskih elektrana može se dodatno klasificirati prema horizontu.

Tablica 1: Sumarni prikaz klasifikacije prognoze proizvodnje fotonaponskih elektrana na temelju horizonta predviđanja

Horizont predviđanja	Vrijeme/Period	Uporaba
Vrlo kratkoročni	<1 minute	Kontrola distribucije energije
Kratkoročni	Jedan do nekoliko sati	Planiranje proizvodnje i isporuke energije
Srednjoročni	Jedan tjedan do jedan mjesec	Olakšava planiranje elektroenergetskog sustava i raspored održavanja
Dugoročni	Jedan mjesec do jedne godine	Korisno za proizvodnju, prijenos i distribuciju električne energije

Nadalje, kada se govori o proizvodnji fotonaponskih sustava, modeli korišteni za predviđanje proizvodnje diktiraju podjelu prognoza. Kratkoročno i vrlo kratkoročno predviđanje karakteriziraju tehnike predviđanja koje se temelje na modelima regresije koristeći baze podataka ili na vektorskim modelima kretanja oblaka korištenjem satelitskih slika i vremenima predviđanja ispod 6 sati. Kada su vremena predviđanja veća od 6 sati, opisane metode više nisu točne, a s novim vremenskim okvirom potrebni su i numerički modeli temeljeni na vremenskim prilikama. Konkretno, numerički modeli temeljeni na prognozi vremena koriste se za prognozu sunčevog zračenja u rasponu od šest sati do tjedan ili dva unaprijed.

2.4.3. Probabilističke i determinističke metode prognoziranja

Probabilističke metode pokušavaju aproksimirati vjerojatnost svih mogućih ishoda proizvodnje fotonaponskih elektrana. Ovaj pristup je zasnovan na konceptu vjerojatnosti i koristi se za modeliranje situacija u kojima postoji neizvjesnost. Probabilističke metode pokušavaju kvantificirati neizvjesnost i pružiti raspon mogućih ishoda, zajedno s vjerojatnostima povezanim s tim ishodima.

S druge strane, determinističke metode izrađuju predviđanja proizvodnje fotonaponskih elektrana u budućnosti, bez uzimanja u obzir neizvjesnosti povezane s predviđanjem. Ovaj pristup daje jednoznačnu procjenu proizvodnje fotonaponskih elektrana i ne uključuje raspon pogrešaka povezan s predviđanjem.

Glavna razlika između ove dvije metode leži u tome kako se bave neizvjesnošću. Probabilistička metoda pruža detaljnije informacije o svojem predviđanju, uključujući vjerojatnosti različitih ishoda, dok deterministička metoda daje jedan specifičan predviđeni ishod. U kontekstu predviđanja proizvodnje fotonaponskih elektrana, ova razlika može biti posebno važna, budući da su performanse fotonaponskih elektrana često podložne varijacijama zbog niza faktora, uključujući vremenske uvjete i tehničke aspekte same elektrane [69].

2.4.4. Hibridne metode

Hibridne metode prognoziranja kombiniraju elemente različitih pristupa, poput fizikalnih i statističkih modela, kako bi pružile preciznije i pouzdanije prognoze. Ove metode kombiniraju prednosti različitih modela, koristeći fizikalne modele za modeliranje temeljnih procesa i statističke metode za prilagodbu modela povijesnim podacima s ciljem povećanja točnosti modela.

Primjer hibridne metode uključuje korištenje fizikalnog modela koji proizvođači osiguravaju za fotonaponske module. Taj se model prvobitno koristi za dobivanje inicijalnih rezultata, a potom za

statistički pristup na dobiveni rezultat kako bi se poboljšala preciznost prognoze. Ovaj postupak je bio primijenjen u nekim istraživanjima koja su spojila metode fizikalnog predviđanja sa tehnikama umjetne inteligencije i statistike [70]. Kao rezultat toga, dobivena je hibridna metoda poznata kao Fizikalno-Umjetna neuronska mreža. Ta mreža simulira fizikalni model neba za određenu lokaciju i koristi ovo simulirano zračenje kako bi odredila buduće dnevno ozračenje. Na taj način metoda koristi karakteristike oba pristupa, što pruža precizniju prognozu proizvodnje fotonaponskih elektrana.

Međutim, dok hibridne metode mogu poboljšati točnost prognoza, one također imaju neke potencijalne nedostatke. Na primjer, složenost hibridnih modela može nadmašiti složenost pojedinačnih modela, što može zahtijevati veću količinu računalnih resursa, poput procesorske snage i memorije. Ova povećana složenost također može otežati interpretaciju i razumijevanje rezultata modela. Unatoč svim izazovima, hibridne metode mogu biti vrlo korisne u situacijama gdje su točne prognoze ključne za operativne ili strateške odluke [71].

2.5. Prognoziranje proizvodnje fotonaponskih elektrana na razini regije

Električna energija proizvedena u više solarnih fotonaponskih elektrana može se kombinirati kako bi se formirala regionalna mreža. Model predviđanja može biti dizajniran za predviđanje proizvodnje fotonaponskih elektrana pojedinačnog postrojenja ili za predviđanje proizvodnje na razini jedne regije. Regionalno predviđanje proizvodnje može biti izvedeno na više načina:

- Zbrajanje rezultata (ili prognoza) koje proizvode modeli pojedinačnih postrojenja koje čine regiju ili područje kako bi se napravila prognoza [72].
- Statističko skaliranje prognoza pojedinačnih postrojenja koje čine regiju [73].
- Modeliranje proizvodnje fotonaponskih elektrana za regiju koristeći kombinirane povijesne podatke pojedinačnih postrojenja koje čine regiju.

3. SUSTAV ZA PRIKUPLJANJE I OBRADU PODATAKA

Kako bi se odredio trend promjene naoblake potrebni su ulazni podaci koji sadrže trenutno i prošlo stanje naoblake iznad promatrane FNE. Količina naoblake, pozicija te smjer i brzina kretanja oblaka mogu se odrediti analizom satelitskih i radarskih snimaka naoblake. Baze podataka koje sadrže satelitske snimke nisu pogodne za uporabu u kratkoročnoj prognozi zbog vrlo niske vremenske i prostorne rezolucije. Lokalna, kratkoročna prognoza zahtijeva bazu podataka koja se sastoji od informacija o naoblaci iznad elektrane visoke prostorne i vremenske rezolucije. Jedan od načina generiranja takve baze podataka je uzastopno fotografiranje polusfere neba. Trenutna dostupna rješenja nisu u široj uporabi zbog visoke cijene modula za prikupljanje fotografija. Niža cijena modula povećala bi njihovu primjenu i tako omogućila veću i raznolikiju bazu podataka koja se može koristiti za izradu novih modela.

Modul za prikupljanje podataka o trenutnom dostupnom sunčevom zračenju i o stanju naoblake iznad promatrane elektrane koristi jeftinu širokokutnu kameru kako bi, u zadanim vremenskim intervalima, prikupljao fotografije polusfere neba i spremao ih za daljnju analizu. Osim širokokutne kamere, modul sadrži i senzor za mjerenje sunčevog zračenja koji je sačinjen od male fotonaponske ćelije te modula za mjerenje struje koju generira ta ćelija. Mini-računalo povezuje sve komponente te obrađuje, sprema i šalje prikupljene podatke. Podaci prikupljeni navedenim modulom mogu se koristiti za izradu baze podataka potrebne za trening modela kratkoročne prognoze, te nakon uspješne kreacije modela, modul se može koristiti i u sklopu sustava za kratkoročnu prognozu.

Inovacije u tehnologiji prikupljanja i obrade podataka, poput ovog modula, predstavljaju ključni korak u poboljšanju kratkoročnih prognoza dostupnosti solarne energije. S padom cijena i poboljšanjem tehnologije, takvi sustavi mogli bi postati sveprisutni dio solarne infrastrukture, a čime bi se znatno unaprijedila efikasnost i održivost solarnih elektrana. Točne i brze prognoze mogu pomoći u integraciji solarnih elektrana u elektroenergetsku mrežu, pružajući pouzdane podatke koje operateri mreže mogu koristiti za učinkovitije upravljanje opskrbom energije. Na ovaj se način može smanjiti potreba za skupim i manje održivim rezervnim izvorima energije, te pridonijeti stabilnosti i održivosti cijelog energetskeg sustava.

3.1. Tehničke karakteristike sustava

Prikupljanje, pohrana i obrada podataka ključni su elementi u svakom sustavu za kratkoročno predviđanje proizvodnje FNE. Izbor lokacije na kojoj će se ovi procesi odvijati određuje se prema specifičnim zahtjevima i mogućnostima, bilo da je to neposredno na lokaciji same elektrane ili u nekom istraživačkom centru. Ovaj izbor ima direktan utjecaj na vrstu i kvalitetu podataka koji se prikupljaju, kao i na mogućnosti za njihovu daljnju obradu i analizu.

Modul za prikupljanje podataka trebao bi biti opremljen sa širokokutnom kamerom koja može pokriti veliki prostor neba omogućavajući tako detaljno praćenje stanja naoblake i dostupnosti sunčeva zračenja. Mini-računalo, koje je sastavni dio modula, koristi se za obradu prikupljenih podataka, ali i za koordinaciju ostalih komponenti modula. Popratni senzor, poput onog za mjerenje sunčevog zračenja, pruža dodatne informacije koje mogu poboljšati točnost predviđanja proizvodnje FNE.

Cjenovna dostupnost modula od ključne je važnosti. Niska cijena omogućuje širu uporabu modula koja rezultira kreiranjem veće i detaljnije baze podataka. Takva baza podataka pruža bogatiji izvor informacija za treniranje i testiranje algoritama kratkoročne prognoze, što može dovesti do poboljšanja u njihovoj točnosti i pouzdanosti. Osim toga, niska cijena modula omogućuje fleksibilnost u odabiru lokacija za postavljanje, primjerice uz elektrane koje se nalaze na geografski izazovnim lokacijama ili one koje pokrivaju velike površine.

U konačnici, izbor pravilne tehnologije i infrastrukture za prikupljanje i obradu podataka može značajno utjecati na učinkovitost i točnost kratkoročne prognoze proizvodnje FNE. Stoga, prilikom dizajniranja ovakvih sustava, potrebno je uzeti u obzir sve tehničke i ekonomske faktore.

3.1.1. Modul kamere

Visoka rezolucija modula kamere neophodna je za prikupljanje visoko-detaljnih fotografija neba. Kvaliteta fotografija direktno utječe na točnost i preciznost podataka koji se iz njih mogu izvući. Veća razina detalja na fotografijama omogućuje precizniju analizu stanja naoblake, uključujući prepoznavanje različitih tipova oblaka i njihovu prostornu distribuciju. Ovo je posebno korisno za analizu oblaka na većim udaljenostima od lokacije modula, gdje se manje promjene u stanju naoblake mogu lako previdjeti bez odgovarajuće razlučivosti.

Međutim, veća rezolucija fotografije također dovodi do povećanja količine podataka koji se moraju obraditi i pohraniti. Ovo može proizvesti tehničke izazove, poput potrebe za većom memorijom za pohranu podataka i vremenski duže obrade. U nekim je slučajevima potrebno smanjiti rezoluciju prikupljenih fotografija kako bi se prilagodila kapacitetu obrade i pohrane podataka.

Žarišna duljina objektiva kamere određuje kut gledanja kamere, tj. koliko širok dio neba kamera može pokriti. Za potrebe prikupljanja fotografija polusfere neba, potreban je širokokutni objektiv s vidnim poljem većim od 180 stupnjeva što omogućuje kameri da pokrije čitavu polusferu iznad lokacije, pružajući tako sveobuhvatan pregled stanja naoblake. Ključno je to za precizno predviđanje promjena u proizvodnji solarnih elektrana, budući da kretanja i promjene naoblake utječu na buduću količinu dostupnog sunčevog zračenja.

Raspberry Pi kamera [74], s dimenzijama od 32 x 32 milimetara, prikazana na slici 6, kompatibilna je sa svim verzijama Pi mini-računala. Opremljena je 5-megapikselnim OV5647 senzorom veličine 1/4 inča na koji je montiran širokokutni objektiv. Ovaj objektiv omogućuje podešavanje udaljenosti točke fokusa i posjeduje vidno polje šire od uobičajenih kamera.

Ključne specifikacije Raspberry Pi kamere uključuju:

- Kompatibilnost: podržava sve verzije Raspberry Pi računala
- Senzor: 5 megapikselni OV5647
- Žarišna duljina: 1.55 milimetara
- Kut gledanja: 185 stupnjeva (Podesiva udaljenost fokusa)
- Veličina senzora: 1/4 inča

- Tip senzora: Charge Coupled Device (CCD)
- Otvor blende (f): 2
- Nazivna rezolucija senzora: 1080p
- Rezolucija za fotografije: 2592 × 1944
- Podrška za video snimanje: 1080p30, 720p60 i 640x480p60/90
- Dimenzije: 32 milimetara x 32 milimetara

Ova kamera omogućuje prikupljanje visokokvalitetnih fotografija neba, što je ključno za točnu analizu stanja naoblake. Njena mogućnost podešavanja fokusne udaljenosti omogućuje preciznije praćenje oblaka na velikim visinama, dok široki kut gledanja osigurava sveobuhvatno praćenje neba. Zahvaljujući ovim značajkama, Raspberry Pi kamera idealna je za implementaciju u modulu za prikupljanje podataka o stanju naoblake.




Slika 6: Modul kamere

3.1.2. Mini-računalo

Mini-računalo Raspberry Pi Zero veličine je tek nekoliko centimetara, ali je iznimno snažno s obzirom na svoje dimenzije. To ga čini idealnim za integraciju u module za prikupljanje podataka o stanju neba jer njegova veličina omogućuje lako uklapanje u postojeći sustav, minimizaciju prostornih zahtjeva i opterećenja strukture na koju se montira, čime se, pored niske potrošnje energije, dodatno smanjuju operativni troškovi.

Raspberry Pi Zero, prikazan na slici 7, također ima brojne portove i mogućnosti proširenja koji omogućavaju jednostavno povezivanje sa širokim spektrom senzora i uređaja. To uključuje USB portove, GPIO pinove za direktne električne veze i HDMI port za video izlaz. Njegova integrirana

podrška za Wi-Fi i Bluetooth dodatno proširuje njegove mogućnosti povezivanja, omogućavajući bežičnu komunikaciju s drugim uređajima i internetskim servisima.



Slika 7: Raspberry Pi Zero računalo

Najvažnija značajka ovog mini-računala je njegova podrška za razne operativne sustave i programske jezike. Raspberry Pi Zero može pokretati širok spektar softvera, uključujući operativne sustave poput Raspbian-a i drugih Linux distribucija, te programski jezik *Python* koji je široko korišten za razvoj algoritama za obradu slika i podataka. Ove značajke čine Raspberry Pi Zero idealnim izborom za razvoj naprednih modula za kratkoročno predviđanje proizvodnje elektrane.

Raspberry Pi Zero predstavljen je u studenom 2015. godine kao zamjena za jeftiniji model Raspberry Pi 1 Model A+. Posjeduje 1GHz jednojezgreni procesor, 512MB RAM-a, mini HDMI port, 2 mikro USB porta (od kojih se jedan koristi samo za napajanje) i standardnih 40 GPIO pinova. Kao model s nižom cijenom, ne uključuje Ethernet priključak, stoga je potrebno povezivanje na mrežu preko vanjskog USB adaptera. Međutim, moguće je uspostaviti vezu s računalom preko standardnog mikro USB kabela [75].

Raspberry Pi Zero W, lansiran u veljači 2017. godine, proširenje je izvornog Raspberry Pi Zero s dodanim Wi-Fi i Bluetooth povezivanjem. Ove dodane značajke omogućuju Zero W da se bežično poveže s drugim uređajima i internetom bez potrebe za dodatnim adapterima ili kabelima. Unatoč ovim nadogradnjama, Zero W zadržava malu veličinu i nisku potrošnju energije izvornog Zero modela, čineći ga još privlačnijim za projekte gdje su prostor i energija ograničeni, poput modula za prikupljanje podataka [76].

Kao i originalni Zero, Zero W podržava širok spektar operativnih sustava i programskih jezika, što ga čini fleksibilnim za različite primjene. Uz Wi-Fi i Bluetooth povezivanje, Raspberry Pi Zero W otvara vrata za još širi spektar mogućnosti, uključujući bežični prijenos podataka i daljinsko upravljanje modulima za prikupljanje podataka. S obzirom na sve navedene prednosti, Raspberry Pi Zero W iznimno je pogodan za integraciju u sustav za prikupljanje i obradu podataka.

3.1.3. Prikupljanje informacija o sunčevom zračenju

Informacije o trenutnom sunčevom zračenju prikupljaju se pomoću malog solarnog panela. Struja kratkog spoja solarnog panela u direktnoj je korelaciji sa zračenjem te se iz tog razloga koristi i modul za mjerenje struje. Te dvije komponente zajedno mogu dati informaciju o trenutnom sunčevom zračenju. Sunčevo zračenje, upareno s fotografijom polusfere neba, neizostavni su podaci koje sadrže baze podataka kratkoročne prognoze proizvodnje fotonaponskih elektrana uporabom fotografija neba.

Solarni panel koji se koristi za ovaj zadatak je polikristalni silicijski solarni panel prikazan na slici 8. Dimenzije su mu 45 x 25 milimetara, s izlaznim naponom DC 5V i snagom 0.125 W. Ovaj panel koristi se za pretvorbu solarne energije u električnu energiju.




Slika 8: Mali solarni panel

Modul za mjerenje struje koji je korišten u ovom sustavu je INA219 senzorski modul [77]. Ovaj sofisticirani senzorski modul dizajniran je da pruži iznimno precizna mjerenja struje uz minimalnu pogrešku od samo $\pm 1\%$ u širokom temperaturnom rasponu od -40°C do 85°C . Također, ugrađeni termalni senzor omogućuje mu da vrši korekciju mjerenja kako bi se postigla veća točnost u

različitim radnim uvjetima. Njegova glavna prednost leži u sposobnosti detekcije raspona napona od 0V do +26V, što ga čini pogodnim za praćenje struje i napona u širokom spektru DC sustava. Komunikacija s mini-računalom se ostvaruje putem I2C sučelja, što omogućuje jednostavnu integraciju u različite sustave.

Kompaktnost predstavlja još jednu prednost ovog modula prikazanog na slici 9. S dimenzijama od 25.5 x 22.3 milimetara, lako se uklapa u većinu dizajna bez zauzimanja previše prostora, čineći ga izuzetno korisnim za male, ali snažne uređaje poput modula za prikupljanje podataka. Način na koji INA219 senzorski modul radi omogućuje pouzdan, visoko precizan način mjerenja struje koji u konačnici poboljšava točnost i pouzdanost sustava za prikupljanje podataka.




Slika 9: INA219 modul za mjerenje struje

3.1.4. Kućište modula

Kućište modula ima ključnu ulogu u zaštiti osjetljivih komponenti sustava i osiguranju njihove ispravne funkcionalnosti, čak i u izazovnim vremenskim uvjetima. Posebno je to važno za sustave poput ovog, koji su često izloženi izravnim utjecajima okoliša, uključujući sunčevu svjetlost, vjetar, kišu i ekstremne temperature.

Zbog kompleksnosti sustava, olakšanog sastavljanja i mogućnosti lake reprodukcije, kućište je izrađeno po mjeri za ovu specifičnu primjenu. Za izradu kućišta odabrana je aditivna metoda proizvodnje te je ono 3D modelirano.


Aditivna metoda proizvodnje dopušta visoku razinu složenosti modela, stoga je unutar modela integrirano niz struktura uz vanjsku periferije koja služi kao zaštitna, vodonepropusna površina. U model su uključeni nosači, lokatori, kanali i druge strukture koje omogućuju ili olakšavaju montažu kućišta. Kućište se sastoji od nekoliko dijelova: glavna noseća konstrukcija, pokrov i komponente za montažu na nosivi stup, a konačne dimenzije su mu 90 x 42 x 30 milimetara. Digitalni model kućišta prikazan je na slici 10.



Slika 10: 3D model modula za prikupljanje fotografija polusfere neba; a) Kućište, b) Kućište s komponentama, c) sastavljeni modul s pokrovom

3.2. Sastavljanje i montiranje modula za dohvaćanje podataka i kratkoročnu prognozu

Modul predstavlja složenu konstrukciju koja se sastoji od brojnih komponenti, pažljivo osmišljenih i isprintanih na 3D printeru. Kompleksnost ovog sklopa vidljiva je u kućištu modula koje uključuje nosače za Raspberry Pi računalo i specifične nosače za senzore i kamere. Pokrov modula obuhvaća držač za staklenu kupolu i solarni panel, kao i otvore za montažu pomoću vijaka. Osim ovih komponenti, u sklopu modula nalazi se i adapter za nosivu konstrukciju. Ova dodatna komponenta ojačava cjelokupni modul i služi kao platforma za njegovo spajanje na nosivu konstrukciju. Sastavljeni modul može se vidjeti na slici 11.



Slika 11: Sastavljeni modul

Sastavljeni modul spojen je na adapter za nosivu konstrukciju. Nakon toga, postupak montiranja modula na predviđenu nosivu konstrukciju započeo je s pomoću dvije objumice koje prolaze kroz kanal modeliran unutar adaptera. Nakon provjere i prilagodbe, modul je sigurno pričvršćen na nosivu konstrukciju koja se nalazi neposredno pored fotonaponske elektrane Riteh 1 ispred Tehničkog fakulteta Sveučilišta u Rijeci kao što je vidljivo na slici 12.



Slika 12: Testni poligon za verifikaciju i evaluaciju performansi predloženog modela te usporedbu s drugim modelima

3.3. Popis komponenti

Sveobuhvatan popis komponenti koje se koriste u izradi modula za dohvaćanje podataka i kratkoročnu prognozu prikazan je u tablici 2. Unutar popisa komponenti, pored imena i opisa, nalazi se i stupac koji prikazuje cijene komponenti. Ove informacije omogućuju dublje razumijevanje troškova i resursa potrebnih za izradu ovog modula. Treba napomenuti da se cijene mogu promijeniti ovisno o vremenu i mjestu kupnje, kao i o promjenama na tržištu. Stoga, troškovnik bi trebao biti korišten kao referenca za potencijalnu reprodukciju ili modifikaciju ovog modula. Stvarni troškovi mogu se razlikovati ovisno o lokalnim cijenama, dostupnosti komponenti i izabranim alternativama. Troškovnik pruža temeljni okvir, ali za najpreciznije procjene uvijek se preporučuje provjera trenutnih cijena kod dobavljača.

Tablica 2: Popis komponenti modula za kratkoročnu prognozu proizvodnje FNE

Ime	Opis	Cijena	
		Euro	Kuna
Raspberry Pi kamera	Širokokutna kamera kompatibilna s Raspberry Pi računalom	18.32 €	138 kn
Raspberry Pi Zero W	Mini računalo	27.50 €	207.2 kn
Mali solarni panel	Mali solarni panel dimenzija 45 x 25 mm, nazivnog napona 5V DC i snagom od 0.125 W	1.59 €	12 kn
INA219 modul	Modul za mjerenje struje	7.30 €	55 kn
Kućišta modula	3D printano kućište modula	0.89 €	6.58 kn
Obujmica	Obujmica za montažu kućišta	1.31 €	9.87 kn
	Ukupno	56.91 €	428.65 kn

3.4. Prikupljanje podataka

Prikupljanje podataka ključna je komponenta svakog sustava za predviđanje, uključujući one koje se temelje na neuronskim mrežama. Kada je riječ o predviđanju proizvodnje fotonaponskih elektrana, neuronske mreže postaju iznimno snažan alat, no one zahtijevaju velike količine ulaznih podataka za treniranje. Baze podataka koje sadrže informacije o izlaznoj snazi elektrane i fotografije polusfere neba iznad same elektrane su rijetkost. Da bi se uštedjelo prostor za pohranu, postojeće baze podataka često sadrže fotografije prikupljene s relativno niskom frekvencijom (primjerice, intervali od 10 minuta). Za slučaj kada su fotografije prikupljene u vremenskim intervalima manjim od jedne minute, baza podataka sadrži informacije za samo nekoliko dana u godini. Inovacije po pitanju cijene i dostupne količine prostora za pohranu omogućuju sustav koji bi dohvaćao i spremao fotografije s većom frekvencijom uzorkovanja.

Za potrebe ovog istraživanja razvijen je modul za prikupljanje podataka. Novo-razvijeni modul koristi senzor kamere visoke rezolucije (2592 x 1944 piksela) s integriranim širokokutnim objektivom (žarišna duljina 1.55 milimetara, vidni kut objektiva 185°). Ova širokokutna perspektiva pruža snimanje cijelog neba iznad fotonaponske elektrane, a što je ključno za detekciju nadolazećih oblaka.

Povećana rezolucija fotografija omogućuje preciznije predviđanje i širi vremenski horizont. Oblaci na periferiji fotografije predstavljaju one na većoj udaljenosti od promatrane elektrane. To su oblaci koji bi s vremenom mogli doći do elektrane i potencijalno uzrokovati smanjenje proizvodnje. Veća rezolucija nudi veću točnost pri detekciji tih udaljenijih oblaka i tako povećava područje koje prognoza pokriva.

Prikupljanje podataka ključna je komponenta svakog sustava za dohvaćanje podataka i prognoze. U kontekstu modula razvijenog unutar ovog rada, ovaj proces uključuje skupljanje podataka iz različitih senzora: fotografije iz modula kamere te razinu dostupnog sunčevog zračenja, izmjenjenog indirektno preko modula za mjerenje struje kratkog spoja malog solarnog panela. Kamera je ključan dio modula i koristi se za snimanje fotografija koje su osnova za analizu i prognozu. Ugrađena je u modul, a Raspberry Pi računalo koristi se za kontrolu senzora kamere i dohvaćanje

fotografija. Softver na računalu programiran je da redovito dohvaća i pohranjuje fotografije u predodređenom vremenskom razmaku.

Podaci se također prikupljaju iz ostalih senzora u modulu, poput temperaturnog senzora koji je sastavni dio Raspberry PI računala. Ovaj senzor pomaže u praćenju uvjeta unutar modula i može biti koristan za identifikaciju i rješavanje mogućih problema kao što je pregrijavanje.

Sve prikupljene podatke potrebno je adekvatno obraditi i analizirati. Nakon što se podaci prikupe, Raspberry Pi računalo ih obrađuje i šalje putem mreže na poslužitelja za pohranu. Obrada podataka sastoji se od prilagođavanja rezolucije fotografije prije spremanja te upisa vremena, datuma i informacija o dostupnoj količini sunčeva zračenja u ime fotografije. Novo-kreirana baza podataka može se koristiti za izradu novih alata za predviđanje proizvodnje fotonaponskih elektrana.

Priključak na internet nudi udaljeno prikupljanje i spremanje podataka, kao i izmjenu programa za prikupljanje podataka što, pruža mogućnost dodavanja novih značajki programa te omogućuje optimiziranje postojećeg.


Kada je u pitanju prostor za pohranu, fotografija rezolucije 512x512 piksela, formata .jpg, zauzima približno 150 kB. S obzirom na to da navedeni sustav prikuplja podatke 16 sati dnevno, s intervalima od 10 sekundi, baza podataka za jedan dan sastoji se od 5760 fotografija dnevno koje zauzimaju približno 864 MB na uređaju za pohranu. To bi značilo da se na prijenosnom disku kapaciteta 1000 GB može pohraniti baza podataka za otprilike 1157 dana. Količina memorije potrebna za pohranu informacija o dospjelom sunčevom zračenju zanemariva je u odnosu na količinu podataka potrebnu za pohranu fotografija.

Baza podataka koja pored fotografija polusfere neba sadrži i podatke o dostupnom sunčevom zračenju, može se iskoristiti za razvoj različitih modela poput analize klimatskih promjena i vremenske prognoze [78]. Dodatne informacije sadržane u bazi ne zahtijevaju dodatni prostor na uređaju za pohranu. Podaci o sunčevom zračenju brojanog su tipa i u odnosu na fotografije imaju niske zahtjeve za memorijom.

Raspberry Pi modul i kamera napajaju se putem USB kabela i pretvarača napona s 230V na 5V, nazivne struje 1A. Prijenos podataka izveden je bežično, putem Wi-Fi mreže. Ova jednostavna povezivost olakšava primjenu sustava na velikom broju postojećih fotonaponskih elektrana. U slučajevima kada se sustav za prikupljanje fotografija koristi na udaljenim lokacijama, s obzirom

na nisku potrošnju energije sustava, moguće je koristiti prijenosnu bateriju s ugrađenom fotonaponskom ćelijom kao izvorom napajanja.

Velika dinamika izlazne snage FNE uzrokovana promjenama u naoblaci zahtijeva visoku frekvenciju prikupljanja fotografija neba kao i podataka o izlaznoj snazi promatrane elektrane. Slika 13 ilustrira usporedbu izlazne snage pri visokoj i niskoj rezoluciji. Na slici je vidljivo kako niska rezolucija smanjuje sposobnost detekcije brzih i kratkotrajnih promjena u izlaznoj snazi. Stoga je ovaj sustav za prikupljanje fotografija dizajniran tako da može prikupljati podatke o proizvodnji i fotografije neba s relativno visokom frekvencijom uzorkovanja.



Slika 13: Prikupljanje informacija s intervalom uzorkovanja od 10 sekundi, jedne minute i pet minuta

Dizajn sustava osigurava da se maksimalno iskoriste dostupni resursi i osiguraju najtočnije moguće informacije za daljnju analizu i predviđanje. Precizno praćenje promjena u izlaznoj snazi fotonaponskih elektrana pridonosi boljem razumijevanju i predviđanju utjecaja atmosferskih uvjeta na proizvodnju fotonaponske elektrane, čime je omogućeno bolje planiranje i optimizacija uporabe resursa. Jedna od važnih karakteristika sustava za prikupljanje podataka o nebu iznad FNE je i njegova cijena. Niska cijena omogućuje širu uporabu takvog sustava i bila je jedna od osnovnih smjernica pri dizajniranju ovog modula.

Kroz pažljiv dizajn i implementaciju sustava za prikupljanje podataka, uspješno je kreirana platforma koja može prikupljati, pohranjivati i analizirati velike količine podataka. Ovi su podaci neophodni za uspješno treniranje i implementaciju neuronskih mreža koje mogu točno predvidjeti proizvodnju fotonaponskih elektrana.

U budućnosti, očekuje se daljnje poboljšanje i optimizacija ovog sustava, uzimajući u obzir najnovije tehnološke trendove i znanstvena otkrića. Ovaj rad može pružiti značajan doprinos u razvoju preciznih i učinkovitih modela za predviđanje proizvodnje fotonaponskih elektrana.

3.5. Referentna baza podataka

Referentna baza podataka služi kao standardni skup podataka za evaluaciju i usporedbu različitih metoda, algoritama i pristupa u proučavanju određene tematike ili problema.

U kontekstu istraživanja i razvoja metoda za predviđanje proizvodnje energije solarnih panela, referentna baza podataka fotografija polusfere neba i pratećih meteoroloških uvjeta ima ključnu ulogu. Navedena baza predstavlja opsežnu zbirku podataka koja omogućuje standardizaciju, osigurava kvalitetu i ponovljivost istraživanja unutar određenog znanstvenog polja [79].

Standardizacija baze podataka omogućuje znanstvenicima usporedbu rezultata i metoda na temelju jedinstvenog skupa podataka. To dovodi do veće preciznosti i pouzdanosti rezultata, a što je od ključne važnosti za napredak u proučavanju kratkoročnih prognoza proizvodnje energije solarnih panela.

Detaljna dokumentacija o opremi korištenoj za prikupljanje podataka, geografskoj lokaciji i godišnjim meteorološkim uvjetima u promatranoj regiji, omogućuje znanstvenicima bolje razumijevanje referentne baze podataka. Sve to doprinosi boljem tumačenju rezultata dobivenih korištenjem ove baze podataka za treniranje i provjeru modela.

3.5.1. Upotreba referentne baze podataka u istraživanju

Referentna baza podataka fotografija polusfere neba i popratnih meteoroloških uvjeta koristi se za razvoj i testiranje algoritama koji predviđaju proizvodnju fotonaponskih elektrana na temelju analize niza slika i meteoroloških podataka. Kroz ovu je primjenu omogućen razvoj algoritama za procjenu oblačnosti i sunčevog zračenja, temeljenih na analizi slika polusfere neba. Takvi algoritmi uključuju one za segmentaciju oblaka [80], praćenje kretanja oblaka [81] i procjenu sunčevog zračenja [82].

Navedena baza podataka također služi kao standard za ocjenu točnosti i pouzdanosti razvijenih metoda, omogućavajući tako validaciju i usporedbu različitih algoritama i pristupa za predviđanje proizvodnje energije solarnih panela. Osim toga, pomaže i u identifikaciji čimbenika koji utječu na točnost i pouzdanost algoritama za predviđanje proizvodnje energije solarnih panela [83]. Takvi čimbenici mogu uključivati kvalitetu slika, razlučivost podataka, vremensku rezoluciju mjerenja te utjecaj lokalnih i regionalnih meteoroloških uvjeta.

Referentna baza podataka pruža platformu za suradnju među istraživačima različitih disciplina i raznih geografskih regija, potičući tako interdisciplinarnu suradnju i razmjenu znanja. Takva vrsta suradnje može potaknuti generiranje novih ideja, pristupa i inovacija, ubrzavajući time napredak ne samo u istraživanju vezanom za prognozu proizvodnje solarnih panela, već i u širem kontekstu obnovljivih izvora energije. Osim toga, referentna baza podataka služi kao dugoročni izvor podataka, koristan za edukaciju novih generacija istraživača i stručnjaka u području predviđanja proizvodnje energije solarnih panela. Očuvanje i stalno unapređenje ove baze podataka omogućuje trajnu dostupnost znanja i iskustava u ovom sektoru te tako osigurava održivost istraživanja i kontinuirani napredak.

3.5.2. Objava referentne baze podataka

Za objavu referentne baze podataka odabrana je platforma Kaggle. Kaggle je jedna od najpoznatijih platformi za podatkovnu znanost i strojno učenje. Osnovana 2010. godine, Kaggle je platforma koja omogućuje korisnicima pristup velikom broju javno dostupnih skupova podataka, stoga predstavlja idealnu platformu za objavu baze podataka kreirane unutar ovog rada.

Kaggle znanstvenicima diljem svijeta uz postojeće skupove podataka pruža i različite alate za obradu i analizu. Jedna od ključnih značajki Kagglea je omogućavanje transparentnosti i suradnje među korisnicima. Ovo je posebno korisno pri kreiranju i objavljivanju referentne baze podataka jer omogućuje korisnicima pružanje povratnih informacija, dijeljene ideje i opći doprinos unapređenju baze podataka.

Kaggleova pravila omogućuju korisnicima objavljivanje svojih skupova podataka u javnoj domeni, a svim korisnicima platforme pristup, preuzimanje i korištenje tih podataka za svoja istraživanja. Ovaj aspekt posebno je važan za ovaj rad jer osigurava distribuciju kreirane referentne baze podataka široj zajednici, pružajući tako mogućnosti za daljnja istraživanja i razvoj na ovom području.

Objavljivanje baze podataka na Kaggleu također podrazumijeva postavljanje metapodataka koji opisuju skup podataka koji pomaže korisnicima razumijevanje prirode i konteksta podataka. Pri objavljivanju referentne baze podataka ovaj je korak iznimno važan jer metapodaci pružaju neophodan kontekst i informacije potrebne za pravilnu interpretaciju i upotrebu podataka.

Metapodaci o skupu podataka uključuju tehničke specifikacije korištene kamere: senzor kamere je 5-megapikselski OV5647, sa žarišnom duljinom od 1.55 milimetara i kutom gledanja od 185 stupnjeva. Veličina senzora je 1/4 inča, a tip senzora je Charge Coupled Device (CCD). Otvor blende (f) je 2, a nazivna rezolucija za fotografije je 2592×1944 . Rezolucija fotografija skupa podataka je 512×512 piksela, a format pohrane fotografije je JPG.

Vremenski razmak između dohvaćanja fotografija je 10 sekundi, a vrijeme dohvaćanja fotografija je od 5:00 do 21:00 sati. Informacije o sunčevom zračenju prikupljene su pomoću malog solarnog panela dimenzija 45×25 milimetara, s izlaznim naponom DC 5V i snagom 0.125 W. Informacije o sunčevom zračenju prikupljene su indirektno mjerenjem struje kratkog spoja panela INA219 modulom za mjerenje struje. Upravljanje modulima, obrada i pohrana podataka ostvareni su Raspberry Pi Zero W mini-računalom.

Vrijeme i datum prikupljanja fotografije i informacije o sunčevom zračenju nalaze se u imenu fotografije. Ime fotografije ima oblik YYYY-MM-DD-HH-MM-SS_SolarRadiatonValue, primjer: 2023-04-21-06-40-13_1.2.

Modul za prikupljanje podataka nalazi se ispred zgrade Tehničkog fakulteta Sveučilišta u Rijeci u Hrvatskoj. Modul je postavljen na geografskim koordinatama 45.337172, 14.425783 i orijentiran je prema jugu. Podaci se prikupljaju od 19. travnja 2023. godine i periodično se dodaju u bazu podataka.

Prema Köppenovom sustavu klasifikacije klime, ovo područje ima umjereno toplu vlažnu klimu s vrućim ljetom, označenu kao Cfa (C=umjerena klima, f= nema sušnog razdoblja, tj. svi su mjeseci vlažni, a= vruće ljeto; srednja temperatura najtoplijeg mjeseca viša je od 22 °C) na klimatskim kartama [84].

Rijeka se nalazi u primorskoj Hrvatskoj na sjevernom Jadranu, te ima umjerenu mediteransku klimu. S obzirom na klimu u gradu Rijeci, može se očekivati da su ljeta topla, suha i većinom vedra dok su zime umjereno hladne, s čestim oborinama i djelomično oblačne. Grad je poznat po svojim vjetrovima, uključujući buru koja može donijeti nagli pad temperature i jasno nebo, ali i jugo koje često donosi oblačno vrijeme i oborine.

Za pristup referentnoj bazi podataka može se koristiti poveznica pod navodom [85]. Ova poveznica vodi direktno na stranicu na Kaggle platformi gdje je postavljena baza podataka. Platforma omogućuje preuzimanje cijelog skupa podataka ili pojedinačnih datoteka prema vlastitim potrebama. Vrijedno je napomenuti da pristup i preuzimanje podataka s Kaggle platforme može zahtijevati registraciju ili prijavu na platformu. Ako korisnički račun ne postoji, registrirati se može e-mail adresom ili putem Google, Facebook ili LinkedIn računa. Nakon uspješne prijave, moguće je pristupiti skupu podataka i koristiti sve prednosti Kaggle platforme.

4. KVANTITATIVNA PROCJENA AMPLITUDNIH VARIJACIJA IZLAZNE SNAGE FOTONAPONSKE ELEKTRANE


U ovom poglavlju obrađuje se kvantitativna procjena amplitudnih varijacija izlazne snage fotonaponske elektrane. Određuje se udio karakterističnih naoblaka kroz godinu te se analiziraju dvije grupe specifičnih scenarija kako bi se utvrdila potreba za sustavom kratkoročnog prognoziranja proizvodnje fotonaponske elektrane.

Podaci o izlaznoj snazi fotonaponske elektrane prikupljeni tijekom 216 dana koristit će se u ovom poglavlju kako bi se kvantitativno procijenila količina energije sadržane u prijelaznim pojavama uzrokovanim promjenama u naoblaci. Cilj ovog istraživanja jest osigurati dublje razumijevanje amplitudnih varijacija u proizvodnji fotonaponske elektrane.

4.1. Statističke informacije

Kako bi se provela analiza potrebe za sustavom kratkoročne prognoze proizvodnje fotonaponskog sustava, neophodna je baza ulaznih podataka. Ulazni podaci sastoje se od broja oblačnih dana u godini i podataka o proizvodnji fotonaponske elektrane. Analizom podataka moguće je izračunati prosječnu količinu energije koja se nalazi unutar vremena naglog smanjenja proizvodnje. Taj nedostatak energije potrebno je nadomjestiti energijom iz drugih elektrana kao što su primjerice vršne plinske elektrane. Proizvodnja električne energije takvim elektranama skuplja je od proizvodnje iste energije u baznim elektranama što dovodi do povećanja cijene električne energije.

Duljina trajanja dana period je tijekom 24 sata kada se na promatranoj lokaciji pojavljuje direktno sunčevo zračenje. Ona ovisi o geografskoj lokaciji te dobu godine. Koristeći prije spomenute podatke i podatke o vremenu za određenu regiju moguće je dobiti prosječnu vrijednost sunčanih sati po godini. Slika 14 prikazuje kartu s grafikonom trajanja sunčeva zračenja u satima po godini za različite dijelove Europe.



Slika 14: Kartografski prikaz broja sunčanih sati u Europi [86]

Za potrebe ovog istraživanja, koristi se informacija o trajanju sunčeva zračenja na lokaciji grada Rijeke. Podaci su prikupljeni putem internetske stranice *Current Results/weather and science facts* dostupne pod navodom [87]. Navedena internetska stranica pruža korisne sažetke obrada objavljenih podataka i znanstvene radove vezane za vremenske podatke.

Tablica 3 pruža pregled srednjih vrijednosti godišnje količine sunčeva zračenja urbanih sredina Republike Hrvatske. U tablici su prikazane tri vrijednosti za svaki pojedini grad. Vrijednost “% Sunce” predstavlja prosječan broj sunčanih sati kroz dan. “Sati” je ukupan broj sunčanih sati godišnje dok je “Dani” tipičan broj dana u godini u kojima je naoblaka prisutna više od 20% vremena. Podaci prikazani u tablici 3 izračunati su uporabom podataka prikupljenih u periodu od 1971. do 2000. godine. Iz podataka prikazanih u tablici vidi se da količina naoblake znatno varira između gradova unutar relativno male regije. Stoga su podaci o naoblaci korišteni unutar ovoga rada prikupljeni pomoću meteorološke stanice prikazane na slici 15 koja se nalazi na glavnoj zgradi Tehničkog fakulteta u Rijeci na udaljenosti od 80 metara od fotonaponske elektrane Riteh 1 čiji su podaci korišteni za daljnju analizu.

Tablica 3: Meteorološki podaci za odabrane gradove u Republici Hrvatskoj

<i>Grad</i>	<i>Rijeka</i>	<i>Hvar</i>	<i>Zagreb</i>	<i>Varaždin</i>	<i>Osijek</i>
% Sunce	55	65	47	51	45
Dani	76	124	49	56	72
Sati	2190	2738	1898	2008	1898



Slika 15: Meteorološka postaja smještena na glavnoj zgradi Tehničkog fakulteta Sveučilišta u Rijeci

Analiza podataka prikupljenih s meteorološke postaje pokazuje da je tijekom 2018. godine na lokaciji solarne elektrane zabilježeno 145 oblačnih dana. Iako će se ovi podaci koristiti za daljnju analizu, važno je napomenuti da broj oblačnih dana tijekom godine varira ovisno o mjestu promatranja i godini za koju su podaci prikupljeni. Ukupan godišnji broj oblačnih dana određen je usporedbom proizvedene energije za svaki dan u godini s proizvedenom energijom prvog susjednog dana za koji zabilježeni podaci ukazuju na vedro vrijeme, odnosno maksimalnu moguću proizvodnju. Ako je energija proizvedena tog dana bila manja od 50% proizvodnje energije najbližeg sunčanog dana, pretpostavka je da je dan bio oblačan.

4.2. Promjena izlazne snage fotonaponskog postrojenja tijekom oblačnog dana

Dinamična priroda analiziranog sustava zahtijeva visoku stopu uzorkovanja podataka kako bi se uočile sve prijelazne pojave u proizvodnji električne energije. Takvi se podaci koriste za određivanje učestalosti pojavljivanja promjena u proizvodnji, te apsolutne vrijednosti i brzine kojom se mijenja izlazna snaga fotonaponskog postrojenja. Skup podataka koji je korišten za analizu dobiven je iz mjerenja provedenih na fotonaponskoj elektrani Riteh 1 prikazanoj na slici 16. Nazivna snaga fotonaponskog postrojenja je 3.5 kilovata (kW). Fotonaponski paneli montirani su na dvoosni solarni sustav za praćenje položaja Sunca [88]. Podaci su mjereni u vremenskom intervalu od 45 sekundi od 05. srpnja 2019. do 08. prosinca 2019. i pohranjeni na server [89]. Razdoblje mjerenja podataka pogodno je za analizu budući da je tijekom cijelog razdoblja mjerenja postojala velika raznolikost vremenskih uvjeta. Od 216 dana za koje su podaci izmjereni u visokoj vremenskoj razlučivosti, 142 dana sadrže upotrebljive podatke što je dovoljan skup podataka za izvođenje analize. Vremenski uvjeti za ta 142 dana kategorizirani su u četiri skupine prema stupnju naoblake - oblačno (24 dana), pretežno oblačno (41 dan), djelomično sunčano (33 dana) i sunčano (44 dana). Podaci za preostala 72 dana ne koriste se u analizama zbog praznina u snimkama uzrokovanih nepouzdanom internetskom vezom i održavanjem servera.



Slika 16: Fotonaponska elektrana Riteh 1


Za proračun se koriste dvije karakteristične skupine vremenskih uvjeta. Prvu karakterističnu skupinu (skupinu A) čine dani s vedrim vremenom uz povremenu naoblaku koja je stvarala sjenu na lokaciji elektrane, dok drugu skupinu (skupinu B) čine dani s visokim stupnjem naoblake i povremenim sunčevim zrakama koje su dopirale do elektrane. Na slikama 17 i 18 prikazani su grafikoni proizvodnje električne energije za jedan dan iz svake od ovih dviju karakterističnih skupina.

Broj oblaka koji prolaze iznad fotonaponske elektrane značajno varira iz dana u dan, stoga su za potrebe istraživanja unutar ovog rada kreirane dvije navedene skupine karakterističnih dana. Skupinu A čine podaci za 23. svibnja 2019., 18. lipnja 2019., 16. srpnja 2019., 3. kolovoza 2019. i 8. srpnja 2019., dok skupinu B čine podaci za 26. svibnja 2019., 14. srpnja 2019., 18. srpnja 2019., 8. veljače 2019., 10. prosinca 2019. i 11. travnja 2019.


Skupina A sadrži dane u kojima je veliki broj manjih oblaka prolazio iznad fotonaponskog postrojenja što je rezultiralo velikim brojem značajnih promjena u proizvodnji energije, pri čemu je svaka promjena kratko trajala. Grafikon prikazan na slici 17 prikazuje brojne promjene u

proizvodnji električne energije za jedan odabrani dan. Skupina B (jedan odabrani dan prikazan je na slici 18) opisuje potpuno oblačne dane s razdobljima u kojima su postojali kratki prekidi u naoblaci koji su doveli do skokova u proizvodnji.

Drugi grafikon na slikama 17 i 18 prikazuje vremensku derivaciju proizvodnje električne energije koja prikazuje promjene u proizvodnji za dva odabrana karakteristična dana. Vremenska razlika Δt je 45 sekundi kao i vrijeme koje se koristi pri prikupljanju podataka o proizvodnji. Grafikoni pokazuju velik broj promjena u razinama izlazne snage koje imaju relativno visoku amplitudu u usporedbi s izlaznom snagom prije i nakon prijelazne pojave.



Slika 17: Proizvodnja električne energije i njena vremenska derivacija na djelomično oblačan dan



Slika 18: Proizvodnja električne energije i njezina vremenska derivacija za vrijeme oblačnog dana

Grafične vrijednosti veličina proizvodnje električne energije korištene u daljnjoj analizi, prikazane su u tablici 4. Drugi redak predstavlja relativne grafične vrijednosti. Razna područja uporabe modela prognoze kao što su predviđanje proizvodnje električne energije, izračun zahtjeva za skladištenje energije, odabir razine rotirajuće rezerve i izračuni stabilnosti napona koriste različite amplitude promjene snage kao donju granicu ulaznih podataka. Zbog toga se promjene u proizvodnji klasificiraju prema različitim grafičnim vrijednostima kako bi se dobiveni rezultati mogli koristiti u različitim primjenama kao što su: planiranje i aktiviranje rezervi, operativno planiranje, trgovanje električnom energijom, kratkoročno trgovanje električnom energijom, upravljanje zagušenjem itd.

Tablica 4: Granične vrijednosti koje se koriste u izračunima

<i>Snaga (W)</i>	2450	2100	1750	1400	1050	700	350
<i>P / Pn (%)</i>	70	60	50	40	30	20	10

U tablici 5 prikazan je prosječan broj prijelaznih pojava u izlaznoj snazi zabilježenih na solarnoj elektrani kroz karakteristične dane podijeljene u dvije ranije opisane skupine. Prvi stupac prikazuje relativnu promjenu u proizvodnji električne energije unutar 45 sekundi, dok drugi i treći stupac pokazuju prosječan broj pojava te promjene u zadanoj skupini karakterističnih dana. Drugi stupac prikazuje prosječne podatke za skupinu A - djelomično oblačni dani, dok treći stupac prikazuje prosječne podatke za skupinu B - oblačni dani.

Tablica 5: Broj prijelaznih pojava u skupinama A i B

	<i>Skupina A</i>	<i>Skupina B</i>
ΔP	<i>Prosjek (n)</i>	<i>Prosjek (n)</i>
$\Delta P > 70\%P_n$	1	0.8
$\Delta P > 60\%P_n$	4.8	3.4
$\Delta P > 50\%P_n$	8	7.2
$\Delta P > 40\%P_n$	13.4	12.8
$\Delta P > 30\%P_n$	20.2	22.6
$\Delta P > 20\%P_n$	33	38
$\Delta P > 10\%P_n$	55.4	61.2
$\Delta P < -10\%P_n$	53.4	63
$\Delta P < -20\%P_n$	34.4	35.6
$\Delta P < -30\%P_n$	20.4	21.2
$\Delta P < -40\%P_n$	13	13.2
$\Delta P < -50\%P_n$	7.6	7
$\Delta P < -60\%P_n$	4.4	2.4
$\Delta P < -70\%P_n$	0.2	0.8

Tablica 6 prikazuje amplitude snage prijelaznih pojava uzrokovanih promjenom naoblake. Vrijednosti su klasificirane u gore opisane grupe pragova minimalne promjene što omogućuje korištenje dobivenih rezultata u različitim primjenama. Isto tako, skupine A i B opisuju različite scenarije vremenskih uvjeta koje su dalje podijeljene po apsolutnoj vrijednosti promjene izlazne

snage, kao i promjene u izlaznoj snazi tijekom perioda povećanja i smanjenja izlazne snage. Iznosi snaga prikazani su u apsolutnim kao i relativnim vrijednostima u odnosu na nazivnu snagu promatrane elektrane. Vrijednosti prikazane u tablici 6 srednje su vrijednosti za sve dane unutar skupine.

Tablica 6: Promjene u proizvodnji fotonaponskih elektrana

Stopa rampe promjene izlazne snage							
Apsolutna (W)	$\Delta P > 350$	$\Delta P > 700$	$\Delta P > 1050$	$\Delta P > 1400$	$\Delta P > 1750$	$\Delta P > 2100$	$\Delta P > 2450$
Relativna (% Pn)	$\Delta P > 10$	$\Delta P > 20$	$\Delta P > 30$	$\Delta P > 40$	$\Delta P > 50$	$\Delta P > 60$	$\Delta P > 70$
Skupina A							
Ukupna promjena u proizvodnji fotonaponske elektrane:							
Apsolutna (W)	1386.92	1131.26	841.12	627.48	417.62	263.38	37.95
Relativna (% Pn)	6.05	4.93	3.67	2.74	1.82	1.15	0.17
Porast:							
Apsolutna (W)	697.44	559.54	420.73	317.62	212.75	137.21	31.74
Relativna (% Pn)	3.04	2.44	1.84	1.39	0.93	0.60	0.14
Pad:							
Apsolutna (W)	689.49	571.72	420.39	309.86	204.87	126.17	6.21
Relativna (% Pn)	3.01	2.49	1.83	1.35	0.89	0.55	0.03
Skupina B							
Ukupna promjena u proizvodnji fotonaponske elektrane:							
Apsolutna (W)	1353.56	1029.20	739.14	506.78	306.19	141.06	42.75
Relativna (% Pn)	5.90	4.49	3.22	2.21	1.34	0.62	0.19
Porast:							
Apsolutna (W)	680.26	530.49	380.69	252.88	156.61	81.75	21.78
Relativna (% Pn)	2.97	2.31	1.66	1.10	0.68	0.36	0.10
Pad:							
Apsolutna (W)	673.30	498.71	358.45	253.91	149.59	59.31	20.97
Relativna (% Pn)	2.94	2.18	1.56	1.11	0.65	0.26	0.09

Iz rezultata prikazanih u tablici 6 može se vidjeti da amplitude promjene izlazne snage fotonaponskih elektrana tijekom prijelaznih pojava unutar dana s promjenjivom naoblakom nisu

zanemarivih veličina. Ako se uzme u obzir ukupna energija sadržana u prijelaznim pojavama, ta energija iznosi oko 5% ukupne energije proizvedene u promatranim danima.

Kod fotonaponskih elektrana manje instalirane snage promjene u izlaznoj snazi ne utječu negativno na elektroenergetski sustav. U novije vrijeme ubrzano raste integracija obnovljivih izvora u elektroenergetski sustav čime se pojavljuju i fotonaponske elektrane veće nazivne snage. Fotonaponske elektrane relativno velike nazivne snage imaju veći utjecaj na elektroenergetsku mrežu tijekom nepredvidljivih promjena izlazne snage uzrokovanih promjenama dostupnog sunčevog zračenja. Zbog toga su podaci prikazani u apsolutnim i relativnim vrijednostima što ih čini korisnim za sve veličine FNE.

Pri korištenju podataka za analizu prijelazne energije većih FNE treba uzeti u obzir da vremenski uvjeti ovise o regiji u kojoj se elektrana nalazi, stoga dobivene podatke treba preračunati uzimajući u obzir prosječni broj oblačnih dana za tu regiju.

Isto tako, za veće elektrane prijelazni učinci mogu se ublažiti. Oblaci mogu zasjeniti samo jedan dio elektrane, dok ostatak elektrane može normalno funkcionirati. Osim zasjenjenja, isti se učinak javlja s povremenim sunčevim zrakama koje dopiru do panela inače oblačnog dana i iako je elektrana velike nazivne snage, takvi događaji mogu proizvesti relativno mala povećanja proizvodne snage u odnosu na iste uvjete iznad manjih elektrana.

Zaključno, kratkoročno predviđanje dostupne solarne energije omogućuje operaterima elektroenergetskih sustava pripremu sustava na nadolazeće promjene u razini proizvodnje FNE. Ovaj alat uvelike pomaže u danima kada je proizvodnja solarne energije karakterizirana naglim promjenama izlazne snage. Osim što operateru sustava daje dovoljno vremena da se pripremi za nadolazeće promjene u razini solarne proizvodnje, adekvatna solarna prognoza omogućuje maksimalno iskorištavanje potencijala solarne energije.

Povećanjem udjela solarnih elektrana u strukturi proizvodnih jedinica energetskeg sektora, povećavaju se i poteškoće koje donose nepredvidljivi obnovljivi izvori energije. Potrebno je pripremiti sustav za veću integraciju kako velikih solarnih elektrana, tako i onih relativno niske nazivne snage. Takve male fotonaponske elektrane obično su priključene na strani potrošača kojom operator prijenosnog sustava ne može direktno upravljati, ali se predviđanje njihove proizvodnje

električne energije može napraviti predviđanjem sunčevog zračenja na određenom geografskom području.

S druge strane, negativan utjecaj obnovljivih izvora energije može se smanjiti ograničavanjem izlazne snage. Ipak, ograničenje izlazne snage ima svoje nedostatke. Ako je proizvodnja solarne elektrane ograničena zbog velikih promjena u njejoj proizvodnji, dolazi do gubitka energije koja bi inače bila proizvedena iz čistih, obnovljivih izvora energije. Stoga je potrebno s velikom razinom sigurnosti predvidjeti buduće razine proizvodnje fotonaponskih elektrana kako bi se smanjile količine izgubljene energije.

U slučajevima kada proizvodnja fotonaponske energije nije ograničena, a energija se predaje sustavu, ostale elektrane u elektroenergetskom sustavu moraju smanjiti svoju proizvodnju kako bi održale ukupnu ravnotežu proizvedene i potrošene energije. Korištenje vršnih elektrana ne samo da rezultira povećanjem cijena električne energije, već i povećanjem štetnih emisija. Vršne elektrane imaju znatno nižu učinkovitost, a zbog vrste goriva koja se najčešće koristi, emisije koje proizlaze iz tih elektrana nepovoljne su za okoliš.

5. MODEL ZA KRATKOROČNU PROGNOZU IZLAZNE SNAGE FOTONAPONSKIH ELEKTRANA

Ovo poglavlje posvećeno je razvoju i implementaciji hibridnog modela koji kombinira konvolucijske neuronske mreže (eng. *convolutional neural network*, CNN) i mreže dugotrajne kratkoročne memorije (eng. *long short-term memory*, LSTM). Cilj ovog kombiniranog pristupa jest stvoriti precizan model za predviđanje buduće proizvodnje fotonaponske elektrane. Izbor hibridnog CNN-LSTM modela mreže temelji se na njegovim specifičnim sposobnostima koje omogućuju efikasno izvlačenje prostornih obrazaca iz fotografija i vremenskih značajki iz sekvenci podataka.

Konvolucijske neuronske mreže ključne su za opremanje modela s kompetencijama računalnog vida. One omogućuju obradu vizualnih podataka s fotografija polusfere neba te omogućuju identifikaciju i učenje ključnih značajki unutar fotografija kao što su: oblici i pozicije oblaka, promjene u osvjetljenju i općenite vizualne obrasce. S druge strane, LSTM mreže posebno su dizajnirane za obradu podataka vremenskih serija, s mogućnošću prepoznavanja i učenja dugoročnih i kratkoročnih trendova u podacima. To obuhvaća prepoznavanje dnevnih i sezonskih ciklusa te vremenskih serija meteoroloških podataka, koji su od ključne važnosti za precizno predviđanje proizvodnje u fotonaponskim elektranama.

Kroz integraciju ove dvije vrste mreža, hibridni CNN-LSTM model postaje moćan alat za prognoziranje buduće proizvodnje fotonaponske elektrane. Njegova sposobnost da istovremeno obrađuje prostorne informacije iz fotografija i vremenske podatke iz serija podataka dovodi do povećane točnosti i robusnosti predviđanja. Ovaj složeni hibridni pristup pruža modelu sposobnost da obuhvati širi spektar informacija, omogućujući mu da efikasno izvodi predviđanja na temelju bogatog, višedimenzionalnog seta podataka. Kao rezultat toga, hibridni CNN-LSTM model pruža visoko sofisticiran pristup predviđanju proizvodnje fotonaponskih elektrana, pružajući obećavajuće rezultate u pogledu točnosti i pouzdanosti predviđanja.

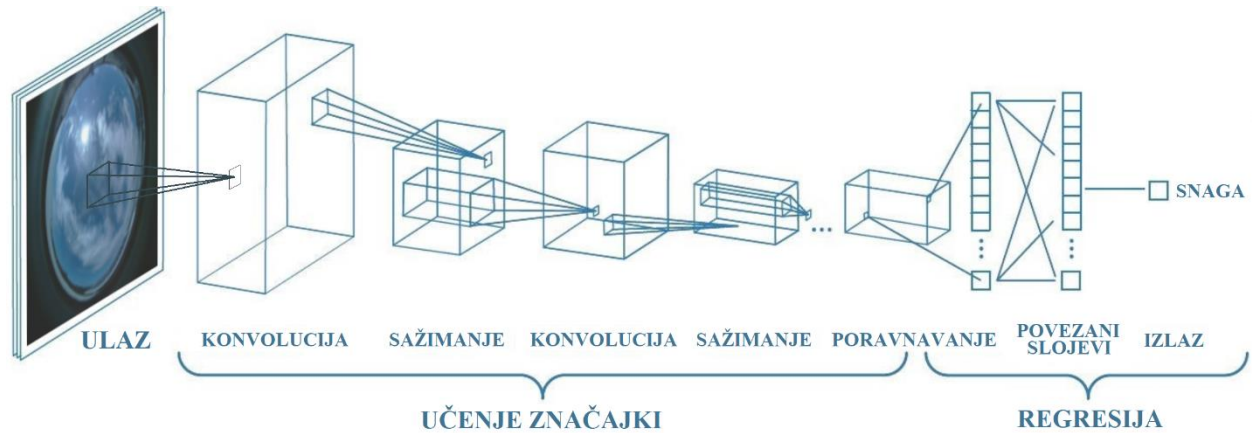
5.1. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (eng. *convolutional neural network*, CNN) predstavljaju posebnu kategoriju modela dubokog učenja koje su specifično dizajnirane za obradu vizualnih podataka, uključujući fotografije i videozapise [90]. U kontekstu predviđanja proizvodnje fotonaponskih sustava, CNN se široko koriste za obradu meteoroloških podataka u obliku fotografija kao što su satelitske slike i radarske snimke [91].

Tipičan CNN model složeno je strukturiran i sastoji se od različitih slojeva, svaki s određenim zadacima i funkcijama. Ovi slojevi uključuju konvolucijske slojeve koji su odgovorni za detekciju lokalnih značajki unutar podataka, slojeve aktivacije koji uvode nelinearnost u model, slojeve grupiranja (eng. *pooling layers*) koji se koriste za smanjenje dimenzionalnosti podataka, te potpuno povezane slojeve koji obavljaju klasifikacijske ili regresijske zadatke na temelju izvučenih značajki [92].

Treniranje CNN mreža izvodi se kroz sofisticiranu metodu koja koristi tehniku propagacije unatrag i optimizaciju putem gradijentnog spusta. Ovaj proces osmišljen je tako da minimizira greške predviđanja, prilagođavajući parametre modela kako bi se bolje prilagodio podacima [93].

Ukupno gledajući, konvolucijske neuronske mreže predstavljaju ključan alat u skupu metoda dubokog učenja, posebno kada se radi o analizi i interpretaciji vizualnih podataka. Njihova sposobnost prepoznavanja i učenja složenih oblika unutar fotografija čini ih neophodnim u brojnim primjenama, od prepoznavanja fotografija do napredne analize videa. Struktura tipične konvolucijske neuronske mreže prikazana je na slici 19.



Slika 19: Struktura tipične konvolucijske neuronske mreže

5.2. Mreže dugotrajne kratkoročne memorije

Mreže dugotrajne kratkoročne memorije (LSTM) specijalizirani su tip rekurentnih neuronskih mreža (eng. *recurrent neural network* (RNN)) posebno dizajniranih za obradu sekvencijalnih podataka i učenje dugoročnih zavisnosti [94]. U kontekstu predviđanja proizvodnje fotonaponske elektrane, LSTM mreže koriste se za analizu vremenskih serija meteoroloških podataka kao što su temperatura, brzina vjetra i solarna radijacija.


Arhitektura LSTM modela se sastoji od memorijskih ćelija, a svaka od njih sadrži tri različita tipa vrata: ulazna vrata koja kontroliraju dotok informacija u memorijsku ćeliju; vrata zaborava koja određuju koje informacije zadržati ili odbaciti; i izlazna vrata koja kontroliraju odljev informacija iz memorijske ćelije [95]. Ova struktura prikazana je na slici 20. Zahvaljujući ovim vratima, LSTM može učinkovito učiti i zadržati dugoročne zavisnosti unutar sekvencijalnih podataka, pružajući rješenje za problem nestajućeg gradijenta koji je prisutan kod konvencionalnih RNN [96].

Treniranje LSTM-a obuhvaća metode poput propagacije unazad kroz vrijeme i optimizacije gradijentnog spusta koje ciljaju na minimiziranje greške predviđanja [97]. Ova sofisticirana metoda omogućuje modelu da identificira i shvati složene vremenske uzorke i međuzavisnosti podataka, što je ključno za precizno predviđanje proizvodnje fotonaponskih elektrana.

Međutim, snaga LSTM modela nije samo u njegovoj sposobnosti da procesira sekvencijalne podatke. Taj je model također iznimno prilagodljiv i može se kombinirati s drugim vrstama mreža za stvaranje hibridnih modela. Primjerice, kombinacija LSTM-a i konvolucijskih neuronskih mreža (CNN) rezultira hibridnim CNN-LSTM modelom, koji može istovremeno izvlačiti i kombinirati prostorne i vremenske značajke, čime se postiže još veća točnost u predviđanjima.

U zaključku, LSTM mreže predstavljaju ključan alat u dubokom učenju, posebno kada su u pitanju sekvencijalni podaci. Njihova sposobnost da efikasno nauče i zadrže dugoročne zavisnosti unutar ovih podataka omogućuje im da budu nezamjenjivi u širokom spektru aplikacija, od prirodne obrade jezika do prediktivne analitike i vremenskih serija.

Kada su implementirane u polju solarne energije, LSTM mreže omogućuju stručnjacima da bolje razumiju i predviđaju proizvodnju energije. Navedeno se postiže analiziranjem vremenskih serija meteoroloških podataka i učenjem o složenim uzorcima i međuzavisnostima koje utječu na proizvodnju električne energije [98]. Ove duboko ukorijenjene spoznaje pružaju temelj za poboljšane strategije upravljanja i optimizacije u proizvodnji solarne energije, omogućujući efikasniju i održiviju upotrebu ovog obnovljivog izvora energije. Bilo da se koriste samostalno ili u kombinaciji s drugim modelima dubokog učenja, LSTM mreže pokazuju se kao izuzetno važan alat u modernom svijetu strojnog učenja i dubokog učenja, omogućujući precizna i korisna predviđanja u širokom spektru polja i disciplina.



Slika 20: Artiktura LSTM mreže [95]

5.3. Baze podataka korištene za trening mreže

U procesu izrade modela za kratkoročnu prognozu proizvodnje fotonaponskih elektrana koriste se dvije različite baze podataka. Prva baza podataka namijenjena je izradi baznog modela, a sadrži podatke prikupljene tijekom višegodišnjeg razdoblja i služi kao temelj za inicijalni razvoj i trening modela.

Druga baza podataka koristi se za fino podešavanje baznog modela i specifična je za lokaciju fotonaponske elektrane čija se izlazna snaga predviđa. Ova baza podataka sastoji se od fotografija polusfere neba te popratnih meteoroloških uvjeta snimljenih na toj konkretnoj lokaciji. Fino podešavanje baznog modela pomoću ovih specijaliziranih podataka omogućuje bolju prilagodbu modela specifičnim uvjetima i potrebama elektrane, postizujući tako veću preciznost u kratkoročnom predviđanju izlazne snage.

5.3.1. Višegodišnja baza podataka za trening baznog modela

Višegodišnja baza podataka koja se koristi za trening baznog modela za kratkoročno predviđanje proizvodnje fotonaponske elektrane preuzeta je s web stranica Sveučilišta Stanford u Kaliforniji [39]. Izbor ove baze podataka bio je vođen s nekoliko ključnih kriterija. Prvi je visoka frekvencija uzorkovanja fotografija polusfere neba uz odgovarajuću izlaznu snagu fotonaponske elektrane u neposrednoj blizini. Drugi je vremenski period tijekom kojeg su podaci prikupljeni. Baza podataka koja obuhvaća višegodišnji period omogućila je modelu da uči i detektira sezonske obrasce u proizvodnji fotonaponske elektrane, što poboljšava njegovu preciznost i pouzdanost. Ova baza podataka pokazala se kao prikladna za potrebe izrade modela kratkoročnog predviđanja, pružajući visokokvalitetne, detaljne i relevantne podatke potrebne za učinkovit trening mreže.


Višegodišnja baza podataka sastoji se od obrađenih fotografija polusfera neba rezolucije 64×64 piksela te podataka o proizvodnji fotonaponske elektrane koja se bilježi u intervalima od jedne minute. S obzirom na to da su podaci predobrađeni, ovaj je skup podataka idealan za razvoj modela dubokog učenja.

Kako bi se ovi podaci mogli pravilno iskoristiti za treniranje, nužno je izvršiti njihovu predobradu i podjelu na odgovarajuće skupove. Ova predobrada uključuje smanjenje broja kanala boja na fotografijama čime se postiže pojednostavljenje modela, smanjenje veličine skupa podataka i ubrzanje procesa treniranja. Podaci su podijeljeni na dva skupa. Prvi skup sadrži podatke za trening i validaciju, koji uključuje 349372 fotografije i pripadajuće podatke o snazi proizvodnje fotonaponske elektrane. Drugi skup sadrži podatke za testiranje, uključujući 14003 fotografije i pripadajuće podatke o proizvodnji.

Svi ovi podaci prikupljeni su u periodu od ožujka 2017. do prosinca 2019. godine na kampusu Sveučilišta Stanford u Kaliforniji. Prema Köppenovom sustavu klasifikacije klime, ovo područje ima mediteransku klimu s toplim ljetima, označenu kao Csb (C=umjereni klima, s=suho ljeto, b=toplo ljeto) na klimatskim kartama. S obzirom na klimu, može se očekivati da je veći dio godine nebo vedro, dok su zime djelomično oblačne.


Slika 21 prikazuje distribuciju podataka o proizvodnji fotonaponske elektrane za razvojni i testni skup podataka. Ova distribucija pruža uvid u raznolikost uvjeta u kojima se elektrana nalazila, obuhvaćajući široki raspon scenarija, od optimalnih, sunčanih uvjeta do oblačnih i manje idealnih uvjeta.

Posebno je prikazano 20 odabranih dana iz testnog skupa, ukazujući na profile proizvodnje fotonaponske energije za te dane. Kao što je prikazano, testni skup uključuje i sunčane i oblačne dane, osiguravajući da model bude dobro obučen za prepoznavanje i interpretaciju različitih vremenskih uvjeta. Takva vrsta distribucije čini ovu bazu podataka izuzetno vrijednom za treniranje modela koji je sposoban precizno predvidjeti proizvodnju fotonaponskih elektrana bez obzira na vremenske uvjete.



Slika 21: Distribucija podataka o proizvodnji fotonaponske energije u referentnom skupu podataka: A. distribucija PV podataka u skupu za razvoj; B. distribucija PV podataka u testnom skupu; i C. profili proizvodnje fotonaponske energije za 10 sunčanih dana i 10 oblačnih dana korištenih u testnom skupu

Slika 22 prikazuje primjere fotografije neba snimljene pod različitim vremenskim uvjetima, što daje dobar pregled široke palete uvjeta koje model mora naučiti prepoznati i interpretirati. Slika 22 također prikazuje kameru i fotonaponske panele koji su korišteni za prikupljanje podataka, dajući dodatan kontekst ovom projektu.



Slika 22: Fotografije neba i opreme za prikupljanje podataka. (A. Fotografija neba snimljena na vedar dan u 12:18:20 , 25. siječnja 2019. B. Fotografija oblačnog dana snimljena u 12:32:10 , 27. svibnja 2019. C. Kamera s širokokutnim objektivom koja je korištena za snimanje neba. D. Fotonaponska elektrana čija se izlazna snaga koristi. E. Lokacije kamere i fotonaponskih panela)

5.3.2. Specijalizirana baza podataka za fino podešavanje

Specijalizirana baza podataka napravljena je za potrebe finoga podešavanja modela koji se razvija u ovom radu. Tehničke detalje o postupku prikupljanja i obrade podataka mogu se pronaći u poglavlju 3, dok su karakteristike podataka sadržanih u bazi detaljnije objašnjene u poglavlju 3.5.2.

Ova specijalizirana baza podataka obuhvaća ukupno 293754 fotografije, zajedno s popratnim informacijama o proizvodnoj snazi malog solarnog panela. Podaci su prikupljeni u periodu od 11. srpnja do 6. rujna 2023. godine, što iznosi 57 dana. Sedam dana iz ovog perioda sadrži nepotpune informacije i stoga su isključeni iz analize. Ostatak perioda koji čini 50 dana, koristi se za podjele na skupove za treniranje i validaciju. Skup za testiranje obuhvaća podatke prikupljene tijekom šest dana, što čini 12% ukupne veličine baze podataka.

U cilju usklađivanja s baznim modelom koji je treniran na višegodišnjoj bazi podataka, podaci su skalirani. Naime, perioda uzorkovanja povećan je s početnih 10 sekundi na jednu minutu. Dodatno, vrijednosti o izlaznoj snazi malog fotonaponskog panela također su skalirane. U tom kontekstu,

sve su vrijednosti skalirane s faktorom 150 kako bi se uskladile sa stvarnim izlaznim vrijednostima snage fotonaponske elektrane Riteh 1.

Ova specijalizirana baza podataka omogućuje fino podešavanje baznog modela, a također služi kao validacijski okvir za ocjenu performansi modela u stvarnim uvjetima.

5.4. Strukturiranje i podjela baze podataka

Baza podataka koja sadrži fotografije polusfere neba s informacijama o datumu, vremenu i izlaznoj snazi fotonaponske elektrane (FNE) u njihovim imenima, predobrađena je i spremljena u .numpy datoteke zbog lakše daljnje obrade. Svaki je dan tretiran kao zasebna jedinica, pri čemu su podaci za svaki dan spremljeni u zasebne datoteke. Za testni skup odabrani su specifični dani i oznaka u imenu datoteke koja naznačuje da se podaci za taj dan koriste za testiranje.

U ovom se radu koristi prilagođeni pristup za podjelu podataka na skupove za treniranje, validaciju i testiranje. Podaci su najprije učitani iz različitih .numpy datoteka, gdje svaka datoteka sadrži podatke za jedan dan. Ove su datoteke pregledane i podaci su dodani u dva različita skupa. Ako ime datoteke sadrži oznaku "TEST", podaci se dodaju u testni skup. Ako oznaka "TEST" nije prisutna, podaci se dodaju u skup za treniranje i validaciju.

Podjela podataka na skupove za treniranje i validaciju provedena je koristeći funkciju za generiranje slučajnih brojeva. Kako bi se osigurala ponovljivost rezultata, postavljen je početni broj za generator slučajnih brojeva. Ovim se postupkom osigurava da se isti skup dana odabere za validaciju svaki put kada se kôd pokrene.

Za podjelu na skupove izračunat je broj dana uključen u validacijski skup, određen kao 30% ukupnog broja dana. Zatim su nasumično odabrani indeksi tih dana. Podaci za ove indekse dodani su u validacijski skup, dok su podaci za sve ostale indekse dodani u skup za treniranje.

Nakon podjele podataka svaki je skup konvertiran u numpy niz. To je postignuto spajanjem svih podataka za svaki skup u jedan niz. Ova metoda osigurava organiziranost skupa podataka po danima i čuvanje vremenske strukture podataka.


Rezultirajući skupovi za treniranje i validaciju sadrže podatke za različite, ali specifične dane, čime se osigurava pouzdano okruženje za treniranje i validaciju modela na podacima koji vjerno reflektiraju stvarne uvjete korištenja.

5.5. Mjerenje stvarne izlazne snage promatrane fotonaponske elektrane

Testni poligon za verifikaciju i evaluaciju točnosti predviđanja razvijenoga modela sastoji se od modula za prikupljane fotografija polusfere neba i fotonaponske elektrane Riteh 1. Verifikacija modela provodi se usporedbom predviđenih i stvarno izmjerenih vrijednosti izlazne snage elektrane. U tu su svrhu prikupljeni podaci o stvarnoj izlaznoj snazi fotonaponske elektrane. Podaci su prikupljeni uređajem za mjerenje i analizu kvalitete električne energije *Metrel MI 2892 Power Master*. Mjerenja su izvedena tijekom sedmodnevnog perioda koji je započeo 23. kolovoza 2023., s intervalom uzorkovanja od jedne minute.

Važno je napomenuti da je sustav dvoosnog praćenja položaja sunca na fotonaponskoj elektrani deaktiviran tijekom mjerenja te je tada elektrana postavljena u horizontalni položaj. Navedena konfiguracija odabrana je kako bi bila usklađena s položajem modula za prikupljanje podataka.

Pregledom prikupljenih podataka, odabrana su dva karakteristična dana na kojima se vrši verifikacija modela. Prvi dan, 27. kolovoza 2023. odabran je zbog stabilnih meteoroloških uvjeta i klasificiran je kao vedar dan. Drugi dan, 29. kolovoza 2023. koji je pretežito oblačan, odabran je kako bi se testirala sposobnost modela kod predviđanja izlazne snage u nestabilnim meteorološkim uvjetima. Variranje naoblake na taj dan predstavlja izazov za model te stoga služi kao dobar testni slučaj. Izlazne snage oba dana prikazane su na slici 23.



Slika 23: Grafički prikaz izlazne snage fotonaponske elektrane Riteh 1 za dva odabrana dana

5.6. Osnovni dijelovi programskog koda

Programski kôd koji je korišten za razvijanje modela opisanih u nastavku ovog rada sastoji se od nekoliko ključnih dijelova. Prije nego što se podaci mogu upotrijebiti u modelu, potrebno je izvršiti njihovu predobradu. Ova obrada podataka neophodna je kako bi model ispravno funkcionirao. Nakon opisa predobrade, opisani su slojevi koji čine neuronsku mrežu modela.


5.6.1. Predobrada podataka

Pri treniranju modela strojnog učenja predobrada podataka postaje ključnim, gotovo nezaobilaznim korakom. Posebno se to odnosi na situacije kada se koriste fotografije visoke rezolucije koje mogu zahtijevati značajne resurse, kako u smislu memorije za pohranu podataka, tako i u pogledu računalne snage potrebne za obradu tih podataka. Stoga je nužno izvršiti određene prilagodbe kao što je smanjenje veličine fotografija kako bi se omogućilo učinkovito treniranje.

Primjerice, velika baza podataka sastavljena je od 100250 fotografija koja se koristi za treniranje modela neuronske mreže. S obzirom na količinu i obujam ovih podataka, bitno je poduzeti korake predobrade kako bi se optimizirala upotreba memorije. Prvi korak u ovom procesu je smanjenje rezolucije fotografije na 64x64 piksela. Ovakvo značajno smanjenje veličine fotografija ne samo da smanjuje potrebe za memorijom za pohranu fotografija, već omogućuje i brže treniranje modela

s manjim opterećenjem na radnu memoriju. Daljnji korak uključuje konvertiranje boja na fotografijama u spektar sivih tonova. Ovaj postupak smanjuje potrebe za memorijom i pojednostavljuje analizu vizualnih značajki koje model koristi za predikciju. Na slici 24 prikazan je proces predobrade nasumice odabrane fotografije.

Iako na prvi pogled ovakve modifikacije mogu djelovati kao da će rezultirati značajnim gubitkom informacija, zapravo se pokazalo da one bitno ne utječu na točnost predviđanja modela. Ključni detalji poput razine naoblake, položaja oblaka te smjera i brzine kretanja oblaka ostaju očuvani čak i na fotografijama niže rezolucije. Fotografije niže rezolucije omogućuju modelu efikasno predviđanje proizvodnje fotonaponske elektrane zadržavajući ključne značajke fotografije. Fotografije niže rezolucije mogu pomoći u minimiziranju šuma i nevažnih detalja koji bi potencijalno mogli ometati rad modela, omogućujući mu da se usredotoči na najrelevantnije informacije. Rezultat je poboljšana efikasnost treniranja koja se očituje u bržem vremenu treniranja i učinkovitijem modelu.



Slika 24: Predobrada nasumice odabrane fotografije: (a) Originalna fotografija; (b) smanjenje rezolucije na 64x64 piksela; (c) konverzija u crno-bijeli format

Međutim, proces predobrade podataka ne završava ovim korakom. Podaci koji se koriste za treniranje modela strojnog učenja moraju proći kroz sveobuhvatni proces predobrade kako bi bili učinkovito iskorišteni za učenje. Ovaj korak uključuje različite postupke, poput normalizacije podataka, eliminacije nedostajućih vrijednosti i segmentacije podataka na setove za treniranje, validaciju i testiranje. Svaka od ovih akcija ima svoju svrhu i važnost.

Normalizacija podataka značajno poboljšava učinkovitost učenja modela jer olakšava detekciju značajki i postizanje stabilnijeg i bržeg učenja. Segmentacija podataka osigurava precizno ocjenjivanje performansi modela i njegove sposobnosti generalizacije na različitim setovima podataka te tako omogućuje objektivnu procjenu modela i bolje razumijevanje njegovih prednosti i ograničenja.

Pored ovih standardnih koraka predobrade, obrada podataka za strojno učenje može uključivati i druge specifične postupke. Na primjer, kada se koristi LSTM (eng. *long short-term memory*) mreža, potrebno je transformirati vremenske serije podataka u sekvence koje su pogodne za trening ove vrste mreže. LSTM mreža koristi sekvence podataka, poput podataka iz vremenskog prozora od 45 minuta koji prethodi promatranom trenutku, kako bi predvidjela proizvodnju fotonaponske elektrane 15 minuta unaprijed. Uzimajući u obzir ograničenje dostupne memorije, dodatni izazov predstavlja i to što svaka epoha treniranja zahtijeva generiranje novog seta podataka koji se sastoji od 32 individualna seta podataka. Svaki od ovih setova sadrži fotografije koje pokrivaju razdoblje od 45 minuta i odgovarajuće informacije o izlaznoj snazi elektrane. Upravo tu predobrada podataka pokazuje svoju vrijednost jer smanjenje rezolucije fotografije i spektra boja, omogućuje više fleksibilnosti i učinkovitije treniranje modela čak i u uvjetima ograničenih memorijskih resursa.

U konačnici, pažljiva i promišljena predobrada podataka ključni je dio procesa treniranja modela strojnog učenja. Kroz primjenu učinkovitih tehnika predobrade optimizira se korištenje raspoloživih resursa, ubrzava proces treniranja te povećava učinkovitost modela. Ovaj se korak ne treba podcjenjivati ili zanemariti jer njegov utjecaj može biti jednako značajan kao i izbor odgovarajućeg modela strojnog učenja ili fino podešavanje hiperparametara.

Pažljivo vođena predobrada podataka može omogućiti brže i stabilnije treniranje, poboljšati sposobnost generalizacije modela i na kraju rezultirati točnijim predviđanjima. Proces predobrade podataka stoga zaslužuje isti stupanj pažnje kao i ostali dijelovi procesa izgradnje modela strojnog učenja.

5.6.2. Standardizacija ulaznih fotografija


Ulazni sloj razvijenog modela prima skup prethodno obrađenih i standardiziranih fotografija. Fotografije koje se koriste u procesu treniranja i prilikom korištenja modela mogu se razlikovati u mnogim aspektima, uključujući format, rezoluciju, spektar boja, proporcije i druge karakteristike.

Kao ključni korak u procesu pripreme podataka, sve ulazne fotografije se normaliziraju kako bi se standardizirale njihove karakteristike. Ovaj korak od presudne je važnosti jer olakšava treniranje mreže, osiguravajući da mreža ne mora prilagoditi svoje težine kako bi se nosila s velikim varijacijama u ulaznim podacima. Normalizacija fotografija usklađuje vrijednosti svih piksela unutar određenog raspona, obično između 0 i 1, što poboljšava stabilnost i performanse treniranja.

Preprocesiranje, uključujući standardizaciju fotografija, provodi se na svim fotografijama koje se koriste za treniranje i validaciju modela kao i na fotografijama koje se koriste u konačnom modelu prilikom stvarne upotrebe. Ovaj proces osigurava da svi ulazni podaci imaju jednake karakteristike, olakšavajući tako njihovo procesiranje od strane modela i poboljšavajući točnost predviđanja.

5.6.3. Ekstrakcija značajki kroz konvolucijske slojeve


Konvolucijski slojevi unutar neuronske mreže koriste se za generiranje novog skupa fotografija - mapa značajki (eng. *feature map*), koje predstavljaju ključne topografske značajke originalne ulazne fotografije. Svaka od ovih mapi značajki generira se koristeći specifični detektor značajki (eng. *feature detector*) kao filter koji može identificirati određene značajke na slici kao što su rubovi, teksture ili oblici. Tijekom procesa treniranja, model se nauči fokusirati na one značajke koje su najkorisnije za točno predviđanje ishoda. Na slici 25 prikazan je odabir slika iz seta generiranih mapa značajki.



Slika 25: Prikaz odabranih mapa značajki generiranih konvolucijskim slojevima neuronske mreže. Svaka mapa značajki pokazuje ključne topografske značajke originalne ulazne fotografije

Iako novi skup fotografija ili mapa značajki može uključivati veći broj fotografija od originalnog ulaznog skupa, svaka od ovih fotografija ima znatno nižu rezoluciju. To se postiže kroz procese konvolucije i grupiranja koji pojednostavljuju informacije na fotografiji, smanjujući time dimenzionalnost i ubrzavajući performanse algoritma. Ovaj proces smanjenja rezolucije, uz ekstrakciju ključnih značajki, ne samo da smanjuje potrebu za velikom računalnom snagom, već i potiče generalizaciju modela. Ovime se povećava sposobnost modela da točno predviđa ishode na temelju novih, prethodno neviđenih slika.

Mapa značajki koja se dobije iz konvolucijskog sloja koristi se kao "ulazna fotografija" za sljedeći sloj u mreži. Ovo može biti sloj maksimalnog grupiranja (eng. *max-pooling*), koji dodatno smanjuje dimenzionalnost podataka, ili novi konvolucijski sloj koji može detektirati još sofisticiranije značajke. Primjer konvolucijskog procesa prikazan je na slici 26.




Slika 26: Konvolucija. a) ulazna fotografija, b) detektor značajki, c) mapa značajki [99]

Tijekom treniranja konvolucijske neuronske mreže, koriste se mnogi različiti detektori značajki. Vrijednosti svakog detektora značajki optimiziraju se tijekom procesa treniranja kako bi se maksimizirala točnost modela u predviđanju željenih ishoda.

5.6.4. Redukcija dimenzionalnosti kroz sloj grupiranja

Sloj grupiranja (eng. *pooling layer*) implementiran je u konvolucijskim neuronskim mrežama s ciljem smanjenja rezolucije dobivenih mapa značajki. Ovaj postupak značajno reducira računalnu snagu potrebnu za daljnje obrade. Za svaki detektor značajki, konvolucijski slojevi generiraju novu mapu značajki. Zatim, sloj grupiranja, dobivene mape značajki komprimira, smanjujući njihovu dimenzionalnost bez gubitka ključnih informacija u njima sadržanih.

Najčešće se koristi metoda maksimalnog grupiranja (eng. *max-pooling*) koja uzima najveću vrijednost iz odabrane podmatrice i koristi je kao reprezentativnu vrijednost za taj dio mape kao što je vidljivo na slici 27. Ovim postupkom smanjenja složenosti podataka doprinosi se bržem treniranju i izvršavanju modela.




Slika 27: Princip rada sloja maksimalnog grupiranja [100]

Važno je napomenuti da, osim što smanjuje računalnu snagu potrebnu za obradu podataka, sloj grupiranja također pomaže u generalizaciji modela. Kompresijom podataka smanjuje se mogućnost pretreniranosti (eng. *overfitting*) neuronske mreže jer model postaje manje osjetljiv na male varijacije u ulaznim podacima. Dakle, sloj grupiranja osigurava da model ostane robustan i kada se koristi za predviđanje ishoda na temelju novih, prethodno neviđenih fotografija.

5.6.5. Poravnavanje podataka i upotreba umjetne neuronske mreže

Sloj za poravnavanje (eng. *flattening layer*) u konvolucijskim neuronskim mrežama koristi se za pretvorbu dvodimenzionalnih matrica ili skupa mapa značajki u jednodimenzionalni niz, odnosno vektor. Ovaj postupak ilustriran je na slici 28. Dobiveni jednodimenzionalni niz služi kao ulaz za sljedeći dio neuronske mreže. Ta sljedeća komponenta može biti umjetna neuronska mreža, duboka neuronska mreža ili potpuno povezani sloj.



Slika 28: Poravnavanje


Umjetna neuronska mreža koristi se za uspostavljanje korelacije između značajki dobivenih iz fotografija i željenog parametra. Svaki "neuron" unutar mreže izračunava zbroj ulaznih vrijednosti i kroz primjenu aktivacijske funkcije, generira izlazni signal. Izlaz svakog neurona na određen je način povezan sa značajkama ulaznih fotografija i ciljanom izlaznom vrijednosti.

Neuronska se mreža može sastojati od jednog ili više slojeva gdje svaki sloj sadrži više povezanih neurona. Kada se mreža sastoji od više slojeva naziva se duboka neuronska mreža. Ova struktura omogućuje modelu da nauči složenije uzorke u obradi podataka, poboljšavajući točnost i učinkovitost predviđanja.

5.6.6. Primjena metode gašenja pojedinih neurona za izbjegavanje pretreniranosti

Metoda gašenja pojedinih neurona (eng. *dropout*) ključna je tehnika za sprječavanje pretreniranosti u neuronskim mrežama [101]. Do pretreniranja dolazi kada model previše precizno nauči obrazac podataka za obuku, što rezultira lošijim performansama na novim, neviđenim podacima. Ovo se događa zato što model nije uspio generalizirati naučene obrasce kako bi bolje predvidio snagu proizvodnje na novim podacima.

Metoda gašenja pojedinih neurona bori se protiv ovog problema kroz nasumično deaktiviranje određenog postotka neurona u svakoj iteraciji tijekom procesa treniranja. Ovo učinkovito mijenja topologiju modela u svakoj iteraciji, stvarajući robusniji model koji bolje generalizira na novim podacima. Primjena metode gašenja pojedinih neurona može rezultirati sporijim postizanjem željene točnosti na podacima za trening, ali točnost na neviđenim podacima obično je značajno veća. Slika 29 ilustrira model neuronske mreže koji koristi metodu gašenja pojedinih neurona.



Slika 29: Gašenje pojedinih neurona neuronske mreže. a) standardna neuronska mreža s 2 skrivena sloja. b) primjer razrijeđene mreže [102]

5.6.7. Izlazni sloj

Izlazni sloj ili posljednji sloj neuronske mreže krajnji je stupanj transformacije u kojem se unutarnje reprezentacije koje mreža nauči iz ulaznih podataka pretvaraju u konačnu izlaznu vrijednost ili vrijednosti koje se koriste za predviđanje. Broj neurona u izlaznom sloju ovisi o vrsti problema koji se rješava. Na primjer, za binarnu klasifikaciju obično je potreban samo jedan neuron koji će izračunati vjerojatnost pripadanja jednoj od dvije klase. Za problem višeklasne klasifikacije, broj neurona obično odgovara broju klasa.

Funkcija aktivacije na izlaznom sloju također se odabire prema vrsti problema. Za regresijske probleme često se koristi linearna funkcija aktivacije koja omogućuje da izlazni sloj proizvodi kontinuirane vrijednosti. Za klasifikacijske probleme, često se koriste sigmoidne (za binarnu klasifikaciju) ili softmax (za višeklasnu klasifikaciju) funkcije aktivacije koje mapiraju izlaze na vjerojatnosti pripadanja različitim klasama.

Funkcija gubitka koja se koristi za treniranje mreže odabrana je na temelju vrste problema koji se rješava i funkcije aktivacije koja se koristi na izlaznom sloju. Funkcija gubitka podatak je koji prikazuje koliko dobro model predviđa ciljne vrijednosti u odnosu na stvarne vrijednosti tijekom treniranja. Ključno je to za optimizaciju modela jer se parametri modela obnavljaju kako bi se minimizirao iznos gubitka. Za regresijske se probleme obično koristi funkcija srednje kvadratne pogreške (MSE) kao funkcija gubitka. Za klasifikacijske probleme, funkcija gubitka obično je *log-loss* (također poznata kao križna entropija) za binarnu klasifikaciju ili kategorička križna entropija za višeklasnu klasifikaciju.

Tijekom treniranja, parametri modela mijenjaju se kako bi se smanjila funkcija gubitka. Ovo se postiže kroz iterativni postupak koji se naziva propagacija unatrag (eng. *backpropagation*) [103], koristeći tehniku optimizacije kao što je stohastički gradijentni spust (eng. *stochastic gradient descent*, SGD), Adam ili RMSprop [104]. Nakon što je model obučen, izlazni sloj generira predviđanja za nove, neviđene podatke. Ove se predikcije onda mogu koristiti za donošenje odluka, predviđanje budućih događaja ili bilo koji drugi relevantan kontekstualni ishod.

5.7. Predviđanje trenutne proizvodnje fotonaponske elektrane uporabom fotografija polusfere neba

Predviđanje trenutne proizvodnje pomoću fotografija polusfere neba postavlja se kao inovativni i koristan pristup u kontekstu ovog rada. Ovaj metodološki pristup djeluje kao temelj za razvijanje modela kratkoročne prognoze proizvodnje fotonaponskih elektrana, pružajući neophodan korak u razvoju modela za buduću proizvodnju.

Razumijevanje modela koji predviđa trenutnu proizvodnju iznimno je važno za daljnji razvoj alata koji bi mogao prognozirati buduću proizvodnju. Nakon što se uspješno razvije model za predviđanje trenutne proizvodnje, sljedeći je korak opremiti taj model s mogućnošću predviđanja buduće proizvodnje.

Postoje različite metode za postizanje ovog cilja. Jedna od opcija uključuje generiranje fotografija koje bi predstavljale buduće stanje neba čime se može procijeniti proizvodnja elektrane.

Alternativno, moguće je koristiti model temeljen na vremenskim serijama čija arhitektura omogućuje prikupljanje, pohranu i interpretaciju podataka o prethodnim obrascima proizvodnje fotonaponske elektrane. Takvi modeli koriste prethodne trendove i obrasce kako bi predvidjeli buduće izlazne snage fotonaponske elektrane. Bilo koja od ovih metoda može pomoći u poboljšanju prediktivnih performansi modela, doprinoseći većoj učinkovitosti u upravljanju fotonaponskom elektranom.

Predviđanje trenutne proizvodnje fotonaponske elektrane upotrebom fotografija polusfere neba može se ostvariti kroz nekoliko različitih metoda. Među najčešće korištenim metodama su linearna regresija, višestruka linearna regresija, i konvolucijska neuronska mreža.

Linearna regresija predstavlja jednostavan statistički model koji procjenjuje odnos između dvije varijable. U ovom slučaju između jedne od informacija sadržanih u fotografijama polusfere neba i trenutne proizvodnje fotonaponske elektrane.

Višestruka linearna regresija proširuje ovaj model tako da uključuje više varijabli, omogućujući modelu da razmotri veći broj faktora koji mogu utjecati na proizvodnju elektrane, poput svjetline fotografije, količine određene boje u fotografiji, omjera srednjih svjetlina boja fotografija i sl.

Konvolucijska neuronska mreža predstavlja napredniju metodu koja koristi duboko učenje za analizu i klasifikaciju fotografija, što je posebno korisno kada se koristi za analizu složenih fotografija poput onih dobivenih fotografiranjem polusfere neba.

Ove tri metode omogućuju različite pristupe predviđanju trenutne proizvodnje fotonaponske elektrane, nudeći fleksibilnost i prilagodljivost u različitim scenarijima i uvjetima.

5.7.1. Konvolucijska neuronska mreža

Predviđanje trenutne proizvodnje fotonaponske elektrane koristi konvolucijsku neuronsku mrežu za analizu fotografija polusfere neba iznad elektrane kako bi se predvidjela trenutna izlazna snaga elektrane. Procjena trenutne proizvodnje ključan je korak u razvoju modela za kratkoročne prognoze proizvodnje fotonaponskih elektrana. Model za predviđanje trenutne proizvodnje fotonaponske elektrane posebno je razvijen za uporabu u fotonaponskim sustavima te je stoga

sposoban postići visoku točnost u predviđanju trenutne snage. Procjena trenutne proizvodnje fotonaponskim elektranama omogućuje korištenje predviđanja sljedećih fotografija u nizu kako bi se predvidjela buduća proizvodnja fotonaponskih elektrana.


Predviđanje trenutne proizvodnje fotonaponskih elektrana oslanja se na analizu atmosferskih uvjeta koji izravno utječu na performanse fotonaponskih sustava. Kao takve, fotografije polusfere neba pružaju korisne informacije o trenutnom stanju atmosfere, uključujući razinu naoblake, intenzitet sunčevog zračenja i druge relevantne faktore.

Konvolucijske neuronske mreže posebno su učinkovite u obradi fotografija i identifikaciji ključnih značajki na fotografijama. U kontekstu fotonaponskih elektrana, CNN može identificirati uzorke na fotografijama neba poput oblika i gustoće oblaka, intenziteta svjetlosti, relativne pozicije Sunca i drugih faktora te ih povezati s trenutnom proizvodnjom fotonaponske elektrane.

Kako bi se to postiglo, model se obučava na skupu fotografija polusfere neba i povezanih podataka o proizvodnji elektrane. Kroz proces učenja, model uči kako različiti vizualni uzorci utječu na proizvodnju energije i stvara interne reprezentacije ovih veza.

Kada se modelu dostavi nova fotografija, koristi se naučenim vezama unutar modela kako bi predvidio trenutnu proizvodnju fotonaponske elektrane. Ova se preciznost u predviđanju može koristiti u sklopu sofisticiranih modela koji predviđaju buduće fotografije polusfere neba.

Model za predviđanje budućih fotografija može analizirati niz prethodnih fotografija kako bi identificirao trendove u kretanju oblaka i promjenama u izlaznoj snazi fotonaponske elektrane. Na temelju tih informacija, model može generirati novu sliku koja predstavlja očekivano stanje neba za primjerice 15 minuta unaprijed kao što je ilustrirano na slici 30. Na temelju ove nove fotografije, razvijeni model zatim može predvidjeti izlaznu snagu elektrane. Ova sposobnost ne samo da omogućuje precizno predviđanje trenutne proizvodnje, već model koristi i ova predviđanja kao temelj za prognoziranje buduće proizvodnje. Prognoza buduće proizvodnje omogućuje operaterima prijenosnog sustava da bolje planiraju i upravljaju elektroenergetskom mrežom, što može dovesti do veće efikasnosti i ušteda.



Slika 30: Predikcija budućih fotografija

Model za predviđanje trenutne proizvodnje fotonaponske elektrane može imati ključnu ulogu u kreiranju sveobuhvatne baze podataka potrebne za treniranje složenijih modela. Ti napredni modeli uz fotografije polusfere neba, zahtijevaju i precizne podatke o trenutnoj proizvodnji fotonaponske elektrane.


Predviđanje izlazne snage na temelju fotografija polusfere neba nudi novu, ekonomičnu alternativu konvencionalnim metodama koje koriste skupe piranometre i složene sustave za prikupljanje podataka o proizvodnji fotonaponskih elektrana. Ova tehnika omogućuje procjenu trenutne proizvodnje fotonaponske elektrane koristeći samo fotografije polusfere neba.

5.7.2. Ulazni podaci

Ulazni podaci za ovo istraživanje proizlaze iz baze podataka koja sadrži fotografije polusfere neba s različitim stupnjevima oblačnosti i odgovarajućim mjerenjima izlazne snage fotonaponske elektrane [105]. Sustav za prikupljanje fotografija konstruiran je od mini-računala Raspberry Pi (Raspberry Pi 3 Model B) i programibilne kamere visoke rezolucije opremljene objektivom širokog kuta. Kontrola nad sustavom ostvaruje se bežično, a programiran je da automatski snima fotografije s intervalom od 10 sekundi od 8:00 do 16:45. Fotografije se zatim pohranjuju u JPG formatu s rezolucijom od 1024x768 piksela.

Kako bi mjerenja izlazne snage fotonaponske elektrane bila što relevantnija, sustav za prikupljanje fotografija smješten je u neposrednoj blizini same elektrane. Fotonaponska elektrana smještena je na krovu Istraživačkog centra za održive zgrade (SBRC) na Sveučilištu u Wollongongu, unutar Inovacijskog kampusa u Australiji (koordinate: 34.40°S, 150.90°E).

Za provedbu ove analize odabrani su podaci za 10. rujna 2019. godine. Baza podataka koja se koristi za ovaj dio istraživanja sadrži ukupno 2978 fotografija. Ovaj specifičan dan odabran je zbog prisutnosti širokog spektra meteoroloških uvjeta, što dovodi do značajnih varijacija u izlaznoj snazi fotonaponske elektrane, kako je vidljivo na slici 31.



Slika 31: Ulazni podaci: Snaga na dan 10. rujna 2019.


Tijekom ranog jutra, od 6 do 9:30, uvjeti su bili pretežno oblačni s povremenim sunčanim razdobljima. Slijedilo je razdoblje vedrine od 9:30 do 11 sati, nakon čega su se počeli pojavljivati oblaci. Zanimljivo razdoblje dogodilo se između 11:30 i 12:30, kada je primijećen efekt ruba oblaka. Tijekom ovog vremenskog intervala, proizvodnja elektrane bila je veća nego što bi se očekivalo na temelju samo direktnog sunčevog zračenja, zahvaljujući doprinosu raspršenog zračenja uzrokovanog obližnjim oblacima. Ovaj efekt ruba oblaka dodatno komplicira integraciju obnovljivih izvora energije u mrežu, budući da može neočekivano povećati ukupnu promjenu u izlaznoj snazi tijekom perioda zasjenjenja [106].

Korištena baza podataka posebno je korisna zbog visoke vremenske rezolucije sadržanih podataka, što pruža mogućnost izgradnje točnijeg modela za predviđanje proizvodnje fotonaponske elektrane. Za preciznu kratkoročnu prognozu proizvodnje neophodno je prikupljanje podataka s visokom vremenskom rezolucijom ($\Delta t < 1$ min), zbog brzih dinamičkih promjena sunčevog zračenja.

Fotografije polusfere neba koje su snimljene na lokaciji elektrane povezane su s trenutnom izlaznom snagom tako da su imena fotografija u bazi podataka prilagođena odgovarajućoj trenutnoj snazi. Za buduće primjene, bazu podataka moguće je proširiti uključivanjem dodatnih informacija u imenima fotografija poput trenutnog vremena, temperature, relativne vlažnosti i slično. Međutim, za potrebe ovog rada, baza podataka sadrži samo fotografije polusfere neba i podatke o izlaznoj snazi elektrane s ciljem pojednostavljenja sustava predviđanja.


Novo-generirana baza podataka, koja sadrži unificirane fotografije i odgovarajuće podatke o izlaznoj snazi, prikazana je na slici 32. Fotografije koje su prikazane na slici 32 nasumično su odabrane iz baze podataka. Ova fotografija također ilustrira korelaciju između količine oblaka te zasjenjenja koje oni uzrokuju i trenutne proizvodnje, što potvrđuje točnost baze podataka.

Metoda koja koristi imena fotografija za pohranu podataka eliminira potrebu za dodatnom bazom podataka koja bi povezivala ime fotografije s parametrima proizvodnje u trenutku kada je fotografija snimljena.



Slika 32: Dio fotografija koje su sadržane u bazi podataka

Slika 33 ilustrira distribuciju ulaznih podataka i tako potvrđuje raznolikost korištene baze podataka. Diversifikacija ulaznih podataka ključna je za razvijanje snažnog i otpornog modela. Široki spektar vremenskih uvjeta predstavljenih u bazi podataka omogućuje modelu efikasnu prilagodbu i anticipiranje vremenskih uvjeta koji su specifični za područje oko elektrane.



Slika 33: Distribucija ulaznih podataka

5.7.3. Linearna regresija

Jednostavnom linearnom regresijom proučava se vezu između dvije varijable. Ako se parovi varijabli X i Y nacrtaju u koordinatnom sustavu dobiva se dijagram raspršenosti. U slučaju da točke prikazane dijagramom raspršenosti izgledaju kao da su raspršene oko nekog pravca, smisleno je promatrati linearnu vezu između X i Y . Navedeni pravac određuje se linearnom regresijom.

$$Y = a \cdot X + b \quad (1)$$

Kako bi taj pravac dobro opisivao vezu između dvije varijable, potrebno je pronaći parametre a i b . Parametar a jest koeficijent smjera i pokazatelj je rastuće ili padajuće veze između X i Y . U slučaju da je $a > 0$, veza je rastuća, dok je u slučaju $a < 0$ veza padajuća. Parametar b označava sjecište pravca i osi y .

Parametri a i b nisu poznati i potrebno ih je procijeniti na osnovi ulaznih podataka. To je moguće napraviti metodom najmanjih kvadrata koja minimizira zbroj kvadrata vertikalnih odstupanja svih točaka od pravca. Pravac $Y = a \cdot X + b$ najbolje aproksimira skup točaka (X_i, Y_i) za $i=1,2,\dots,n$ u smislu da je suma kvadrata udaljenosti između zadanih točaka (X_i, Y_i) i točaka na pravcu $(X_i, aX_i + b)$ minimalna [107].

$$\sum_{i=1}^n [y_i - (a \cdot x_i + b)]^2 \rightarrow \min \quad (2)$$

Unutar ovog rada metoda linearne regresije nad ulaznim podacima provedena je unutar programskog paketa Microsoft Excel.

Jednadžba pravca i koeficijent determinacije izračunati su pomoću dijagrama raspršenosti i umetanja linije trenda koja je izračunata metodom linearne regresije. Osim koeficijenta determinacije, standardna devijacija pokazuje uspješnost aproksimacije podataka. Ona je izračunata korištenjem proširenja programskog okruženja Microsoft Excel pod nazivom Skup alata za analizu (*Analysis ToolPack*) [108].

5.7.4. Višestruka linearna regresija

Kako bi se, pored linearne regresije, izračunala povezanost više parametara fotografije s izlaznom snagom, koristi se višestruka linearna regresija. Kod linearne regresije, model sadrži jednu zavisnu i jednu nezavisnu varijablu, dok kod višestruke ima jednu zavisnu i više nezavisnih varijabli. Fotografije neba, između ostalih, sadrže informacije u tri komponente piksela (crvena, zelena i plava) koje bi mogle biti povezane s izlaznom snagom elektrane na lokaciji na kojoj se nalazi kamera. Višestruka linearna regresija koristi se u slučaju kada postoji linearna ovisnost zavisne varijable o više nezavisnih varijabli. Model višestruke linearne regresije je:

$$y = a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n + \varepsilon \quad (3)$$

Gdje je n broj nezavisnih varijabli.

U slučaju da se analiza radi na temelju m opažanja, za svako opažanje određuje se linearna jednadžba, što znači da se ukupno odredi m linearnih jednadžbi [107]:

$$\begin{aligned}y_1 &= a_1 \cdot X_{11} + a_2 \cdot X_{12} + \dots + a_n \cdot X_{1n} + \varepsilon_1 \\y_2 &= a_1 \cdot X_{21} + a_2 \cdot X_{22} + \dots + a_n \cdot X_{2n} + \varepsilon_2 \\&\vdots \\y_m &= a_1 \cdot X_{m1} + a_2 \cdot X_{m2} + \dots + a_n \cdot X_{mn} + \varepsilon_m\end{aligned}\tag{4}$$


5.7.5. Obrada fotografija

Kako bi se izračunala korelacija stvarne vrijednosti sunčeva zračenja i stanja se detektira pomoću fotografija neba, potrebno je obraditi prikupljene fotografije. Obradom fotografija očitavaju se vrijednosti koje su povezane s količinom sunčeva zračenja. Neke od tih vrijednosti su: ukupna svjetlina fotografije, količina plave boje, omjer plave i sive boje te količina naoblake uporabom granične vrijednosti za detekciju količine oblaka. Daljnja analiza provodi se na navedenim parametrima.

Svjetlina fotografije može ukazati na jačinu sunčeve svjetlosti koja dopire do senzora, ali isto tako može ukazati i na količinu i svjetlinu oblaka obuhvaćenih fotografijom. Svjetlina boja po kanalima – crvena, zelena i plava mogu ukazivati na udio čistog neba (plava boja) ili udio oblaka (siva i bijela boja prikazani su kao kombinacija svih triju dostupnih boja). Kako bi se dobio točniji uvid u količinu plave bolje potrebno je svaki pojedini piksel klasificirati u jednu od kategorija: crvena, zelena, plava i siva boja zato što bijela, siva i plava koriste sličnu vrijednost plave komponente boje (bijela boja se, među ostalima, sastoji i od plave boje). Klasifikacijom piksela moguće je utvrditi stvarni udio plave boje koji ne uzima u obzir bijele ili sive piksele oblaka. Razlika tako izračunatih vrijednosti plave i sive boje može dati uvid u količinu vidljivog plavog neba uključujući tako i razinu naoblake.

Metoda graničnih vrijednosti koristi se kako bi se pomoću kontrasta sadržanog unutar fotografije odredio koji piksel predstavlja oblak, a koji čisto nebo kao što je vidljivo na slici 34. Odnos tih


dviju vrijednosti mogao bi biti koristan za računanje korelacije između podataka sadržanih unutar fotografije i stvarne razine sunčeva zračenja u gledanom trenutku.



Slika 34: Detekcija oblaka metodom graničnih vrijednosti. (a) izvorna fotografija (b) obrađena fotografija

Za obradu fotografija koristi se računalni alat Pillow. Pillow je grana PIL(*Python Imaging Library*) koja dodaje mogućnost procesiranja fotografija u Python razvojnoj platformi. Navedena programska biblioteka omogućuje uporabu više tipova ulaznih podataka, efikasno unutarnje prepoznavanje fotografije koje omogućuje pristup informacijama sadržanih u pojedinim pikselima ili grupama piksela što daje brojne mogućnosti po pitanju obrade fotografije [109].

Crni rubovi fotografija neba ne sadrže informacije o trenutnome stanju nego predstavljaju unutrašnjost kućišta kamere. Odsjaj sunčeva svjetla od objektiva kućišta posvjetljuje navedeni dio fotografije što znatno utječe na srednju vrijednost svjetline fotografije. Kako bi se uklonio negativan utjecaj rubnih dijelova fotografije na promatrane parametre potrebno je digitalno zacrniti (maskirati) dijelove fotografije koji se nalaze van promatrane zone kao što je vidljivo na slici 35. Kako bi se utvrdilo utjecaj maske na korelaciju između informacija sadržanih unutar fotografije i stvarne vrijednosti proizvodnje fotonaponske elektrane, fotografije su obrađene s i bez maske. Dva seta informacija omogućuju usporedbu dviju metoda.



Slika 35: Postupak dodavanja maske na sliku. (a) Izvorna fotografija (b) maska (c) fotografija nakon obrade


Algoritam za obradu fotografija polusfere neba razvijen je unutar Spyder integriranog razvojnog okruženja (eng. *integrated development environment*, IDE) koje je zasnovano na programskom jeziku Python, a razvijeni programski kôd nalazi se u prilogu. Licenca programskog paketa Spyder otvorenog je tipa.

Metode kojima su određeni parametri koji se nalaze unutar fotografije su: Svjetlina - srednja vrijednost, Svjetlina crvene, zelene i plave boje, Količina plave boje (udio piksela), Razlika količine plave i sive boje te Metoda graničnih vrijednosti. Svjetlina - srednja vrijednost kao metoda dobivena je konvertiranjem fotografije u crno-bijelo te određivanjem srednje vrijednosti svjetline svih piksela unutar promatrane fotografije. Svjetlina crvene, zelene i plave boje dobivena je računanjem srednje vrijednosti pojedine boje unutar piksela za sve piksele unutar promatrane fotografije i posebno za svaku od navedenih boja. Količina plave boje (udio piksela) dobivena je sortiranjem svakog piksela koji se nalazi unutar promatrane fotografije u jednu od kategorija: crveni, zeleni, plavi i sivi pikseli. Nakon sortiranja, zbroj plavih piksela podijeljen je s ukupnim brojem piksela kako bi se dobio udio plave boje. Isto tako, zbroj sivih piksela podijeljen je s ukupnim brojem piksela kako bi se dobio udio sive boje. Oduzimanjem tih dviju vrijednosti dobiva se razlika količine plave i sive boje.

Metoda graničnih vrijednosti provedena je uporabom *Adaptive thresholding* funkcije koja se nalazi unutar OpenCV Python biblioteke [110].

Adaptive thresholding funkcija ulaznu fotografiju dijeli na pojedine regije te se unutar svake regije računa iznos granične vrijednosti pomoću koje se svaki pojedini piksel klasificira kao maksimalna ili minimalna vrijednost boje (crni ili bijeli piksel). Nakon obrade računa se srednja vrijednost svjetline dobivene fotografije.

Funkcija *Adaptive thresholding* odabrana je zbog nejednolikog osvjetljenja fotografija što onemogućuje uporabu samo jedne granične vrijednosti za sve piksele unutar fotografije. Na slici 36 može se vidjeti razlika između metode *Simple Thresholding* i *Adaptive thresholding* koje se nalaze unutar OpenCV Python biblioteke. *Simple Thresholding* funkcija za cijelu sliku koristi jednu graničnu vrijednost za sortiranje piksela na crne i bijele dok *Adaptive thresholding* funkcija prije sortiranja sliku dijeli na regije i za svaku regiju zasebno računa graničnu vrijednost.



Slika 36: Metoda graničnih vrijednosti. (a) izvorna fotografija (b) *Simple Thresholding* (c) *Adaptive thresholding* [110]

5.7.6. Model konvolucijske neuronske mreže za predviđanje trenutačne proizvodnje

Model je konstruiran koristeći dubinsko učenje, kombinirajući konvolucijsku neuronsku mrežu (eng. *convolutional neural network*, CNN) i umjetnu neuronsku mrežu (eng. *artificial neural network*, ANN). Ovaj hibridni pristup koristi se kako bi se iskoristile prednosti oba modela: sposobnost CNN-a da izvuče značajke iz fotografija i ANN-ovu sposobnost da na temelju tih značajki generira predikcije.

Ulazni su podaci za model fotografije polusfere neba iznad fotonaponske elektrane. Svaka fotografija prolazi kroz konvolucijsku neuronsku mrežu koja ima ulogu izvlačenja značajki iz fotografija. Ovaj proces koristi višeslojnu arhitekturu, omogućujući modelu da identificira i kategorizira složene oblike i obrasce koji su prisutni na fotografijama.

Unutar konvolucijske neuronske mreže, slojevi *max poolinga* koriste se za smanjenje dimenzionalnosti ulaznih podataka. Ovaj postupak omogućuje modelu da smanji količinu ulaznih podataka, fokusirajući se samo na najvažnije značajke i tako smanjuje rizik od pretreniranosti modela. Konvolucijska neuronska mreža omogućuje modelu da izvuče korisne informacije iz fotografija neba kao što su oblik, tekstura i položaj oblaka.

Nakon procesa konvolucije i *max poolinga*, izvučene značajke se koriste kao ulazni podaci za umjetnu neuronsku mrežu. ANN je vrsta mreže koja se najčešće koristi za predviđanje na temelju izvučenih značajki, zahvaljujući svojoj sposobnosti da nauči složene, nelinearne odnose između ulaznih i izlaznih podataka. Ova mreža koristi značajke koje su dobivene na izlazu konvolucijskog dijela mreže kako bi generirala procjenu izlazne snage fotonaponske elektrane.

Ulaz za ovaj složeni model jednostavna je fotografija polusfere neba iznad fotonaponske elektrane, dok je izlaz modela broj koji predstavlja procijenjenu izlaznu snagu fotonaponske elektrane u trenutku kad je fotografija snimljena. Kombinacija ova dva tipa neuronskih mreža omogućuje precizno i efikasno predviđanje proizvodnje fotonaponske elektrane na temelju vizualnih podataka, čineći ovaj model snažnim alatom za predviđanje proizvodnje obnovljive energije.

Sveobuhvatan prikaz razvijenog modela za predviđanje proizvodnje fotonaponske elektrane na temelju fotografija polusfere neba ilustriran je na slici 37. Ova ilustracija prikazuje sve ključne komponente modela, uključujući strukturu unosa, konvolucijske slojeve kao i izlazni sloj. Također, prikazuje se kako se podaci fotografija polusfere neba procesiraju kroz model kako bi se dobila konačna procjena izlazne snage fotonaponske elektrane.

Osim toga, razumijevanje implementacije ovog modela olakšano je pružanjem pristupa izvornom programskom kodu. Kôd se može pregledati i testirati putem dostupnog linka u referenci, koji vodi do Google Colab notebook-a [111]. Ova platforma omogućuje korisnicima da interaktivno eksperimentiraju s kodom, pružajući dublje razumijevanje o funkcioniranju modela. Također, ovaj pristup potiče otvorenost i ponovljivost istraživanja, što je ključno za znanstvenu zajednicu.

```
Model: "model"
```

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 128, 128, 3)]	0
conv2d (Conv2D)	(None, 126, 126, 32)	896
max_pooling2d (MaxPooling2D)	(None, 63, 63, 32)	0
conv2d_1 (Conv2D)	(None, 61, 61, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 30, 30, 64)	0
conv2d_2 (Conv2D)	(None, 28, 28, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 14, 14, 128)	0
conv2d_3 (Conv2D)	(None, 12, 12, 256)	295168
max_pooling2d_3 (MaxPooling2D)	(None, 6, 6, 256)	0
flatten (Flatten)	(None, 9216)	0
dense (Dense)	(None, 256)	2359552
dropout (Dropout)	(None, 256)	0
power_out (Dense)	(None, 1)	257

```
-----  
Total params: 2,748,225  
Trainable params: 2,748,225  
Non-trainable params: 0  
-----
```

Slika 37: Sumarni prikaz modela

5.8. Rezultati predviđanja trenutne proizvodnje fotonaponskih elektrana

Predviđanje trenutne izlazne snage fotonaponskih elektrana ključan je korak u izradi modela za predviđanje buduće proizvodnje fotonaponskih elektrana. Ovaj odlomak ističe rezultate različitih modela predviđanja trenutne proizvodnje. Modeli, osim što služe kao temelj za primarni model ovog rada, alati su za verifikaciju kvalitete baze podataka.

Modeli koji koriste fotografije polusfere neba kao ulazne podatke, nakon obrade mogu predvidjeti izlaznu snagu fotonaponske elektrane u trenutku kada je fotografija snimljena. Ova metoda

omogućuje provjeru koliko stvarna izlazna snaga elektrane odgovara očekivanoj snazi, uzimajući u obzir utjecaj razine naoblake iznad promatrane elektrane.

Takav pristup može pomoći u otkrivanju potencijalnih pogrešaka u usklađivanju vremenskih oznaka; vremena kada je izlazna snaga elektrane zabilježena i vremena kada je fotografija snimljena. Na taj način, modeli omogućuju precizno i pouzdano ispitivanje integriteta podataka i njihove povezanosti.

5.8.1. Rezultati regresijske analize


Rezultati regresijske analize provedene unutar Microsoft Excel programskog paketa prikazani su u tablici 7. Prvi stupac sadrži imena metoda korištenih za analizu skupa fotografija koje su detaljnije pojašnjene u poglavlju 5.7.5, dok druga dva stupca predstavljaju dvije kategorije obrade ulaznih fotografija, prva je bez maske u kojoj se koriste izvorne fotografije, a druga je s maskom. Fotografije s maskom su prije analize obrađene tako da se dio fotografije koji ne sačinjava pogled na polusferu neba zacrni.

Unutar svake navedene kategorije prikazani su rezultati i to redom: jednadžba pravca aproksimacije, koeficijent determinacije i standardna devijacija.

Tablica 7: Rezultati regresijske analize


Metoda	Cijela fotografija			Maskirana fotografija		
	Jednadžba pravca	Koeficijent determinacije (R ²)	Standardna devijacija	Jednadžba pravca	Koeficijent determinacije (R ²)	Standardna devijacija
Svjetlina - srednja vrijednost	$y = 100.67x - 1017.4$	0.2010	1247.6	$y = 76.768x - 9934.1$	0.0880	1332.9
Svjetlina crvene boje	$y = 5.8255x + 3619.6$	0.0008	1395.1	$y = 164.63x - 30187$	0.1430	1292.0
Svjetlina zelene boje	$y = 55.454x - 127.34$	0.0768	1341.0	$y = 70.403x - 10053$	0.0190	1382.3
Svjetlina plave boje	$y = 100.89x - 5806.4$	0.2783	1185.6	$y = -14.823x + 6737.2$	0.0004	1395.4
Količina plave boje (udio piksela)	$y = 5561.3x - 314.45$	0.1028	1322.0	$y = -247419x + 4140.3$	0.0574	1355.0
Količina sive boje (udio piksela)	$y = -9426.9x + 4191$	0.0026	1393.9	$y = -9426.9x + 4191$	0.0026	1393.9
Razlika količine plave i sive boje	$y = 5422x - 38.469$	0.1017	1322.8	$y = 1495.2x - 11012$	0.0001	1395.6
Metoda graničnih vrijednosti	$y = -8.8362x + 4044.6$	0.0015	1394.7	$y = 9.0088x + 2970.7$	0.0022	1394.2
Srednja vrijednost:	-	0.0957	1325.3	-	0.0391	1367.7

Usporedba stvarne i predviđene snage prikazana je za specifične slučajeve. Grafički prikaz rezultata na slici 38 prikazuje podatke o stvarnoj izlaznoj snazi gledane fotonaponske elektrane i predviđene snage koristeći metodu linearne regresije i ulazne podatke o svjetlini plave boje fotografija polusfere neba iznad elektrane.



Slika 38: Usporedba stvarne i predviđene snage uporabom metode Svjetlina plave boje na cijelim fotografijama

Slika 39 na jednom dijagramu prikazuje stvarnu i predviđenu snagu za slučaj kada se za ulazni podatak koristila svjetlina fotografije obrađena metodom graničnih vrijednosti koja naglašava prisustvo oblaka. Vrijednosti osi stvarne snage prikazani su s lijeve strane, a vrijednosti predviđene snage skalirani i prikazani s desne strane. Granične vrijednosti osi predviđene snage promijenjene su kako bi dijagram bio čitljiviji.



Slika 39: Usporedba stvarne i predviđene snage uporabom Metode graničnih vrijednosti na cijelim fotografijama


Temeljem rezultata regresijske analize prikazanih u tablici 7 odabrani su ulazni parametri za model višestruke linearne regresije.

Rezultati višestruke linearne regresije vidljivi su u tablici 8. Prikazane su kombinacije nezavisnih varijabli kojima je najbolje opisana izlazna snaga fotonaponske elektrane. U drugom retku korištene su sve dostupne varijable, dok su u redcima ispod prikazane kombinacije varijabli koje, koristeći određeni broj varijabli, modelom najbolje opisuju sustav. Sve varijable korištene u tablici 8 izračunate su koristeći cijelu sliku.

Tablica 8: Višestruka linearna regresija

Nezavisne varijable	Broj nezavisnih varijabli	Jednadžba pravca	Koeficijent determinacije (R ²)	Standardna devijacija
Vrijeme, Svjetlina - srednja vrijednost, Svjetlina - efektivna vrijednost, Svjetlina crvene boje, Svjetlina zelene boje, Svjetlina plave boje, Količina plave boje (udio piksela), Količina sive boje (udio piksela), Metoda graničnih vrijednosti	9	$y = 2207.4x_1 + 405.0x_2 - 884.8x_3 + 439.5x_4 - 227.6x_5 + 476.9x_6 - 4382.2x_7 - 6780.2x_8 - 64.0x_9 - 1229.0$	0.828	578.7
Svjetlina - srednja vrijednost, Svjetlina zelene boje, Svjetlina plave boje, Količina plave boje (udio piksela)	4	$y = 316.6x_1 - 522.3x_2 + 327.9x_3 - 2808.4x_4 - 2808.4$	0.803	619.2
Svjetlina - srednja vrijednost, Svjetlina zelene boje, Svjetlina plave boje	3	$y = 212.9x_1 - 444.3x_2 + 324.8x_3 - 5504.0$	0.703	759.0
Svjetlina zelene boje, Svjetlina plave boje	2	$y = -351.7x_1 - 415.9x_2 - 10588.8$	0.657	815.8

Na slici 40 vidljiva je usporedba stvarne snage i snage predviđene modelom višestruke linearne regresije s 9 nezavisnih varijabli.



Slika 40: Usporedba stvarne i predviđene snage uporabom višestruke linearne regresije s 9 nezavisnih varijabli

Tablice 9 do 12 prikazuju rezultate višestruke linearne regresije s devet, četiri, tri i dvije nezavisne varijable gdje su *Standard Error* - standardna devijacija i *P-value* vrijednost je koja prikazuje koliko je svaka pojedina nezavisna varijabla korištena u modelu statistički značajna. P vrijednost može iznositi između 0 i 1 gdje 0 simbolizira visoki statistički značaj gledane varijable na model, dok 1 niski.

Tablica 9: Rezultati višestruke linearne regresije s devet nezavisnih varijabli

	<i>Standard Error</i>	<i>P-value</i>
Intercept	426.53	0.0040
Vrijeme	262.55	6.39E-17
Svjetlina - srednja vrijednost	12.93	1.49E-186
Svjetlina - efektivna vrijednost	102.09	7.18E-18
Svjetlina crvene boje	41.83	2.25E-25
Svjetlina zelene boje	44.44	3.24E-07
Svjetlina plave boje	18.61	5.10E-131
Količina plave boje (udio piksela)	214.86	1.14E-86
Količina sive boje (udio piksela)	1538.69	9.00E-07
Metoda graničnih vrijednosti	4.92	1.21E-37

Tablica 10: Rezultati višestruke linearne regresije s četiri nezavisne varijable

	Standard Error	P-value
Intercept	265.23	1.48E-30
Svjetlina - srednja vrijednost	8.16	3.83E-267
Svjetlina zelene boje	6.66	0
Svjetlina plave boje	6.04	0
Količina plave boje (udio piksela)	169.15	2.76E-59

Tablica 11: Rezultati višestruke linearne regresije s tri nezavisne varijable

	<i>Standard Error</i>	<i>P-value</i>
Intercept	308.87	1.37E-67
Svjetlina - srednja vrijednost	9.87	3.89E-96
Svjetlina zelene boje	7.11	0
Svjetlina plave boje	6.87	0

Tablica 12: Rezultati višestruke linearne regresije s dvije nezavisne varijable

	<i>Standard Error</i>	<i>P-value</i>
Intercept	214.71	0
Svjetlina zelene boje	6.09	0
Svjetlina plave boje	5.83	0

5.8.2. Diskusija regresijske analize

Modeli razvijeni unutar ovog dijela rada primijenjeni su na fotografijama prikupljenima samo na jednoj lokaciji i to za jedan karakterističan dan. Primjenom fotografija prikupljenim u danima u kojima su zabilježene manje meteorološke varijacije, primjerice sunčan dan ili jednoliko oblačan dan, korelacija bi bila znatno veća. Modeli za predviđanje proizvodnje fotonaponskih elektrana pokazuju svoju robusnost na danima sličnima onome korištenome u ovim analizama.

Velika dinamičnost naoblake u promatranom danu omogućuje jasan pregled korelacija različitih parametara sadržanih unutar fotografije sa stvarnom trenutnom proizvodnjom elektrane. Informacije sadržane u skupu fotografija dinamičnog dana daju mogućnost usporedbe korelacija s drugim modelima koji se također testiraju na podacima snimljenim u danima u kojima bi kratkoročna predviđanja proizvodnje fotonaponske elektrane bila najkorisnija.

Iz rezultata je vidljivo da u slučaju kada se analiziraju izvorne fotografije kojima nisu zacrnjeni rubni dijelovi dolazi do najveće korelacije između određenog parametra i stvarne snage proizvodnje. Koeficijent determinacije najveći je kod linearne regresije svjetline plave boje u odnosu na izlaznu snagu elektrane.

Rezultati pokazuju da maskiranje fotografije ima negativan utjecaj na korelacije u svim primjenjenim metodama što bi značilo da su informacije sadržane u dijelovima fotografije koje prikazuju unutrašnjost kućišta, pa tako i odsjaj od kućišta kamere, korisne.

Svjetlina crvene boje pokazuje najmanju korelaciju s izlaznim snagom elektrane, dok je ukupna svjetlina fotografije, drugi najpovezaniji parametar. S obzirom na to da je ukupna svjetlina fotografije - srednja vrijednost svjetlina fotografija po dostupnim kanalima boja, takav rezultat je očekivan.

Na slici 38 prikazana je usporedba stvarne i predviđene snage uporabom metode Svjetlina plave. U slučaju podataka u vremenskom razdoblju bez oscilacija u proizvodnji, primjerice u okolici 10 sati, rezultati pokazuju kako se linearnom regresijom i uporabom ulaznih podataka o svjetlini plave boje unutar fotografije može predvidjeti da nije bilo oscilacija izlazne snage elektrane u promatranom vremenskom razdoblju. Također, nakon 14 sati dolazi do smanjenja izlazne snage zbog azimuta Sunca. Pri zalasku Sunca nebo prelazi iz plave u crvenu boju te se posljedično tome, plava boja potamnjuje. Nedostatak korištenja informacija o svjetlini plave boje jest taj što oblaci, koji su bijele i sive boje, također posvjetljuju plavu komponentu boje. Greška u aproksimiranoj proizvodnji vidljiva je u 9:30 i u 15:30 sati. Na navedenim dijelovima dijagrama vidljivo je da stvarna izlazna snaga zbog naoblake padne, a model predviđa da bi tada trebala porasti.

Veza između svjetline fotografije i količine oblaka dobivena je uporabom Metode graničnih vrijednosti. Nedostatak navedene metode je nemogućnost detektiranja promjene izlazne snage u odnosu na doba dana, to jest azimut, kao što je vidljivo na slici na slici 39.

Uporabom modela višestruke linearne regresije dolazi do znatno veće korelacije između informacija sadržanih unutar fotografija polusfere neba i izlazne snage elektrane na lokaciji na kojoj su prikupljene te fotografije. U tablici 8 prikazani su rezultati višestruke linearne regresije. Uporabom devet nezavisnih varijabli koeficijent korelacije iznosi 82.8%. Uporabom manjeg broja nezavisnih varijabli postiže se zadovoljavajuća korelacija te su rezultati za dvije, tri i četiri nezavisne varijable također prikazani u tablici 8.


U tablici 9 moguće je vidjeti kako P vrijednost za sve nezavisne varijable poprima vrlo nisku vrijednost. Razlog tome je taj što su sve nezavisne varijable osim vremena, određene analizom fotografije gdje svaka pojedina vrijednost utječe na drugu. Primjerice, svjetlina fotografije sastoji se od srednje vrijednosti svih piksela sadržanih u fotografiji, dok svjetlina crvene boje sadrži informaciju samo o svjetlini crvene komponente piksela. Svjetlina plave komponente piksela fotografije i količina plavih piksela zavisne su jedna o drugoj, ali razlikuju se po tome što svjetlina plave komponente piksela uzima u obzir i bijele piksele, dok ih količina plavih piksela zanemaruje.

Razlike između varijabli razlog su veće korelacije uporabom više nezavisnih varijabli. Visoku korelaciju moguće je postići i manjim brojem varijabli upravo zbog njihove povezanosti. Tipično se manji broj nezavisnih varijabli postiže eliminacijom nezavisne varijable s najmanjim statističkim značajem (P vrijednost), a u ovom slučaju, zbog niske P vrijednosti kod svih varijabli, koriste se drugi pokazatelji. Tablica 7 prikazuje korelaciju između svake varijable zasebno u odnosu na izlaznu snagu fotonaponske elektrane. Odabirom varijabli s najvećom korelacijom postiže se i visoka korelacija u slučaju višestruke linearne regresije s manjim brojem nezavisnih varijabli (tablica 10, 11 i 12).

Rezultati istraživanja prikazani unutar ovog dijela rada ukazuju na visoku korelaciju podataka sadržanih unutar fotografije neba iznad fotonaponske elektrane i izlazne snage te elektrane. Uporabom opisanih metoda moguće je, korištenjem samo fotografije neba, s visokom točnošću predvidjeti izlaznu snagu fotonaponske elektrane. Fotografije polusfere neba mogu se prikupiti jednostavnim sustavom koji sadrži jednu kameru i modul za slanje i obradu podataka.


5.8.3. Rezultati modela konvolucijske neuronske mreže

Pokazatelj uspješnosti modela kroz iteracije treninga je funkcija gubitaka (eng. *loss function*). Pogodna je kôd modela za rješavanje regresijskih problema. Slika 41 prikazuje funkciju gubitaka treninga s podacima o gubicima kroz dvjesto iteracija treninga i to za podatke korištene za trening (eng. *Training Loss*) te za podatke korištene za validaciju modela (eng. *validation loss*) koji čine 20% ukupnih podataka.



Slika 41: Funkcija gubitaka treninga

Rezultati modela konvolucijske neuronske mreže provedene unutar Google Colab virtualnog programskog okruženja prikazani su na slici 42. Srednja apsolutna pogreška (eng. *Mean Absolute Error*, MAE) označava prosjek apsolutnih razlika između vrijednosti dobivenih iz modela i povijesnih podataka opažanja. Srednja kvadratna pogreška (eng. *Mean Squared Error*, MSE) je prosječna kvadratna razlika između procijenjenih vrijednosti i stvarne vrijednosti. Korijen srednje kvadratne pogreške (eng. *Root Mean Squared Error*, RMSE) je kvadratni korijen od MSE. Njegova vrijednost je na istoj skali kao i vrijednosti dobivene modelom. Koeficijent determinacije (eng. *Variance score*) je specifičan pokazatelj reprezentativnosti modela. Model je reprezentativniji što je koeficijent determinacije bliži jedinici.



Slika 42: Rezultati modela konvolucijske neuronske mreže

Na slici 43 prikazana je usporedba stvarne i predviđene snage za jednu nasumice odabranu fotografiju.




Image index: 2730
Original Power: 5305
Predicted Power: 5008
Error: -297
Error % : 5.6 %

Slika 43: Prikaz predviđanja snage za nasumice odabranu fotografiju

Grafički prikaz rezultata na slici 44 prikazuje usporedbu stvarne snage s predviđenom snagom za sve ulazne podatke. Analiza je provedena nad bazom podataka za dan 10. rujna 2019., koja se

sastoji od 2978 fotografija polusfere neba i pripadajućim snagama proizvodnje fotonaponske elektrane.



Slika 44: Usporedba stvarne snage s predviđenom snagom

5.8.4. Diskusija rezultata modela konvolucijske neuronske mreže

Model razvijen u sklopu ovog dijela rada testiran je na fotografijama snimljenim na jednoj lokaciji tijekom jednog karakterističnog dana. Koristeći se fotografijama iz dana s manje meteoroloških varijacija, poput sunčanog ili uniformno oblačnog dana, korelacija bi vjerojatno bila značajno veća. Modeli za predviđanje proizvodnje fotonaponskih elektrana pokazuju svoju robusnost na danima sličnima onome korištenome u ovoj analizi. Dinamičnost naoblake tijekom promatranog dana omogućuje jasnu sliku o tome koliko dobro model koji koristi fotografije može predstavljati stvarnu trenutnu proizvodnju elektrane.

Slika 42 prikazuje visoku usklađenost između stvarnih i predviđenih snaga što ukazuje na visoku korelaciju modela i stvarnih fizikalnih procesa. Slika 43 prikazuje predviđanja za jednu nasumice odabranu fotografiju. Fotografija neba karakteristična je po tome što ne prikazuje samo relativnu lokaciju Sunca što indicira doba dana pa tako i dostupno sunčevo zračenje za to doba dana nego i reflektirano sunčevo zračenje s obližnjih oblaka. Može se vidjeti da model pruža visoku točnost iako je na slici prikazana kompleksna naoblaka.

Visoko preklapanje stvarne krivulje proizvodnje i krivulje predviđene proizvodnje temeljem fotografija oblaka vidljivo je na slici 44. U slučaju podataka u vremenskom razdoblju bez oscilacija u proizvodnji, primjerice od 9:50 do 10:30 sati, rezultati pokazuju kako model bez poteškoća predviđa izlaznu snagu. Također, nakon 14 sati, dolazi do smanjenja izlazne snage zbog azimuta Sunca što model također ispravno predviđa. Pri zalasku Sunca nebo prelazi iz plave u crvenu boju te se, posljedično tome, plava boja potamnjuje. Ta činjenica, uz vizualnu lokaciju Sunca, modelu potencijalno omogućuje točno predviđanje. Greška u aproksimiranoj proizvodnji vidljiva je u 8:50 i u 12:20 sati. Na navedenim dijelovima dijagrama vidljivo je da se stvarna izlazna snaga ne poklapa s predviđenom. Model, zbog relativno niskog broja podataka za treniranje, nije pogodan za ekstremne promjene u naoblaci.

Visoku točnost modela moguće je postići i korištenjem većeg broja ulaznih varijabli kao što su brzina vjetera, temperatura, trenutno vrijeme i datum te satelitske i radarske snimke naoblaka. Međutim, sustav se nastoji održati što jednostavnijim tako da koristi što je manje moguće ulaznih podataka što smanjuje njegovu cijenu te potrebu za memorijom i računalnom snagom.

Kako bi se model dodatno generalizirao, potrebno je koristiti veće baze podataka prikupljene na lokacijama elektrana različitih nazivnih snaga.

Algoritam za predviđanje sljedeće fotografije može se koristiti za generiranje budućih fotografija naoblake iznad fotonaponske elektrane [112]. Primjenom tehnika analize fotografija opisanih u ovom radu na takvim novo-generiranim fotografijama, algoritam omogućuje kratkoročno predviđanje proizvodnje fotonaponskog sustava.

Osim toga, algoritam za predviđanje trenutne proizvodnje može pridonijeti pojednostavljenju sustava prikupljanja fotografija. Koristeći ovaj algoritam, modul za kratkoročno predviđanje sastoji se samo od kamere. Trenutna snaga fotonaponske elektrane može se predvidjeti bez potrebe za korištenjem uređaja za mjerenje izlazne snage.

5.8.5. Praktična primjena razvijenog modela za predviđanje trenutne proizvodnje fotonaponske elektrane

Praktična primjena razvijenog modela proširuje se izvan samog kratkoročnog predviđanja trenutne izlazne snage fotonaponske elektrane. Jedna od upotreba ovog modela je za integraciju s postojećim sustavima za upravljanje i održavanje fotonaponskih elektrana. Obrada fotografija polusfere neba u realnom vremenu kako bi se predvidjela očekivana izlazna snaga, modelu pruža mogućnost detekcije anomalija u stvarnoj izlaznoj snazi koje mogu ukazivati na potrebu za održavanjem ili intervencijom.

Primjerice, ako izlazna snaga elektrane konzistentno podbacuje u odnosu na predviđanja modela, to može ukazivati na oštećenje panela ili potrebu za čišćenjem. Time se omogućava dinamička procjena potrebe za održavanjem što može znatno smanjiti troškove i povećati efikasnost elektrane. Uz to, analiza podataka može pružiti vrijedne informacije za optimizaciju raspoređivanja resursa, bilo da se radi o ručnom održavanju ili automatiziranim sustavima za ispiranje panela.

U kontekstu održivog razvoja i maksimalne iskoristivosti resursa, ovakav pristup ne samo da ima prednosti u smislu ekonomske isplativosti, već i u ekološkom. Smanjenje potrebe za nepotrebnim intervencijama minimizira utjecaj na okoliš i pridonosi održivim praksama upravljanja fotonaponskim elektranama.

U konačnici, integracija ovog modela u postojeće sustave upravljanja fotonaponskim elektranama može pridonijeti smanjenju operativnih troškova i povećanju ukupne učinkovitosti. Također, brza i precizna dijagnostika omogućena modelom može biti od pomoći u situacijama kada je brza intervencija ključna, kao što su kritične pogreške ili oštećenja sustava.


5.9. Predviđanje buduće proizvodnje fotonaponske elektrane uporabom fotografija polusfere neba

Model za prognozu izlazne snage fotonaponske elektrane temelji se na CNN modelu za obradu fotografija polusfere neba, detaljno opisanog u odlomku 5.7. Za predviđanje buduće proizvodnje potrebno je obraditi niz fotografija te na temelju njih i povezanih informacija o izlaznoj snazi fotonaponske elektrane, odrediti trend promjene proizvodnje, a time i proizvodnju za sljedećih 15 minuta. S obzirom da CNN model ne posjeduje memoriju, a time ni mogućnost analize prošlih fotografija, razvijen je hibridni model koji kombinira CNN i LSTM arhitekture. Ovaj model obrađuje niz fotografija polusfere neba i pripadajuće podatke o proizvodnji fotonaponske elektrane tijekom prethodnih 45 minuta. Njegov je cilj predvidjeti proizvodnju električne energije 15 minuta nakon posljednje dostupne podatkovne točke.

Usporedba razvijenog modela s ostalim modelima predstavlja izazov jer drugi istraživači koriste različite ulazne podatke, konkretno podatke prikupljene manjom frekvencijom uzorkovanja. Osim toga, drugi modeli treniraju se na ulaznim podacima koji obuhvaćaju različita vremenska razdoblja. Primjerice, ako su podaci upotrijebljeni za razvoj modela prikupljeni u razdoblju od samo jednog mjeseca, može doći do pretreniranosti modela zbog malog broja podataka za trening. U takvim situacijama podaci za trening i validaciju mogu sadržavati dane tijekom kojih je naoblaka bila slična, što može prividno poboljšati poklapanje modela sa stvarnim svijetom. Stoga je, koristeći poznatu metodu trodimenzionalne konvolucijske neuronske mreže (eng. *3-dimensional Convolutional Neural Network*, 3D CNN) [113], razvijen dodatni model treniran na istim podacima kao i hibridni CNN-LSTM model. Korištenjem identičnih podataka za treniranje obje neuronske mreže kao i istog horizonta predviđanja, omogućena je usporedba dvaju modela kako bi se utvrdilo koji je prikladniji za uporabu u predviđanju proizvodnje FNE.

5.9.1. Hibridni CNN-LSTM model

Hibridni model sastoji se od tri glavne komponente: CNN modela za obradu fotografija, LSTM modela za obradu vremenskih serija podataka i dodatnog ulaza za informacije o trenutnoj razini izlazne snage fotonaponske elektrane. Struktura modela prikazana je na slici 45.



Slika 45: Struktura razvijenog hibridnog modela

Komponenta CNN za obradu fotografija razvijena je s ciljem prepoznavanja značajki unutar niza fotografija koje su povezane s izlaznom snagom. Model se sastoji od sljedećih slojeva:

- Konvolucijski sloj koji koristi 32 filtra veličine (3,3) te se služi ReLU aktivacijskom funkcijom;

- Sloj skupne normalizacije integriran je s ciljem poboljšanja stabilnosti modela;
- *MaxPooling* sloj veličine (2,2) konstruiran je zbog smanjenja dimenzionalnosti podataka i isticanja najvažnijih značajki;
- *Dropout* sloj s omjerom ispadanja od 0,3, namijenjen sprječavanju pretreniranosti modela;
- *Flatten* sloj za pretvaranje višedimenzionalnog izlaza u jednodimenzionalni format

U predloženom pristupu, LSTM model se koristi za detekciju vremenskih ovisnosti unutar ulaznih podataka. LSTM model sastoji se od sljedećih slojeva:

- *TimeDistributed* sloj koji primjenjuje prethodno kreirani CNN model na svaki vremenski segment ulazne sekvence i omogućuje modelu učinkovito prepoznavanje vremenskih ovisnosti unutar podataka;
- LSTM sloj s brojem jedinica određenim putem varijable 'lstm_units' (u ovom modelu postavljen na 64), koji koristi 'tanh' za aktivaciju i 'sigmoid' za rekurentnu aktivaciju, omogućujući modeliranje dugotrajnih ovisnosti;
- *Dropout* sloj sa stopom ispadanja od 0,3, čime se sprječava pretreniranost modela

Dodatno, segment za ulaznu snagu omogućuje modelu da uključi trenutnu izlaznu snagu fotonaponskog sustava. Sastoji se od ulaznog sloja oblika (n_input), gdje je n_input broj ulaznih podatkovnih točaka, što je u ovom modelu postavljeno na 45.

Pristup ovom radu u početku je bio korištenje LSTM mreža za obradu podataka o ulaznoj snazi. Navedena metoda odabrana je s obzirom na vremenske značajke ulazne serije podataka. Međutim, performanse modela osjetno su degradirale tijekom testne faze. Hipoteza je bila da vremenske ovisnosti unutar ulaznih podataka o snazi možda nisu tako složene kao one na slikama. Alternativno, obrasci u podacima mogli bi se bolje protumačiti jednostavnijim *Dense* slojevima koji ne sadrže vremensku komponentu. Stoga, kako bi se poboljšala točnost modela, korištenje LSTM-a za obradu ulaznih podataka o snazi je odbačeno.

Nakon kombiniranja CNN i LSTM modela, dodaje se sloj za spajanje koji objedinjuje izlaze LSTM-a i dodatne informacije o ulaznoj snazi. Krajnji ANN sloj s linearnom aktivacijskom funkcijom koristi se za generiranje prognoze proizvodnje fotonaponske elektrane, ujedno i ciljnu varijablu modela.

Kombinirani CNN i LSTM model razvijen u Python programskom jeziku, koristi mogućnosti popularnih knjižnica za duboko učenje TensorFlow [114] i Keras [115], što omogućuje jednostavnu implementaciju i fleksibilnost. Za računalnu infrastrukturu odabran je Google Colab, online platforma koja omogućuje izvođenje Jupyter bilježnica na Googleovim udaljenim poslužiteljima. Ključna prednost platforme Google Colab jest pružanje snažnih grafičkih procesorskih jedinica (eng. *graphics processing unit*, GPU) koje značajno ubrzavaju trening modela. Konkretno, koristi se GPU NVIDIA Tesla V100, poznat po svojim superiornim performansama u treniranju dubokih neuronskih mreža. Uporabom ovog robusnog sustava za treniranje modela omogućeno je brzo treniranje modela. Konkretno, sveobuhvatni trening modela završen je za samo 364 sekunde. Takav brzi trening omogućuje brze iteracije i eksperimente s različitim konfiguracijama modela, što je ključno za preciziranje i optimiziranje efikasnih i preciznih modela dubokog učenja.

Trening modela koristi 'adam' optimizator s funkcijom gubitka srednje kvadratne pogreške (MSE) te srednju apsolutnu pogrešku (MAE) kao mjerilo performansi. Ukupno, kombinirani CNN-LSTM model sadrži 7889582 parametra za treniranje i zauzima 30.1 MB memorije, što je detaljno prikazano na slici 46. Opseg ovih parametara pokazuje složenost modela i njegov potencijal za učenje složenih obrazaca iz ulaznih podataka. Ovaj model, pažljivo konstruiran integracijom različitih slojeva i tehnika, pokazuje se učinkovitim u točnom predviđanju proizvodnje fotonaponske elektrane na temelju sekvenci fotografija polusfere neba i povezanih podataka o proizvodnji. Poveznica u navodu [116] omogućava pregled koda unutar Google Colab bilježnice.

```
Model: "model_1"
-----
Layer (type)                Output Shape                Param #   Connected to
-----
input_2 (InputLayer)        [(None, 45, 64, 64, 1)]    0         []
time_distributed(TimeDistributed) (None, 45, 30752)          320      ['input_2[0][0]']
lstm (LSTM)                  (None, 64)                  7889152  ['time_distributed[0][0]']
input_3 (InputLayer)        [(None, 45)]                0         []
concatenate (Concatenate)   (None, 109)                 0         ['lstm[0][0]','input_3[0][0]']
dense (Dense)                (None, 1)                   110      ['concatenate[0][0]']
-----
Total params: 7889582 (30.10 MB)
Trainable params: 7889582 (30.10 MB)
Non-trainable params: 0 (0.00 Byte)
-----
```


Slika 46: Sažetak arhitekture hibridnog CNN-LSTM modela, prikazujući niz slojeva, njihove izlazne oblike i broj parametara koje je moguće trenirati

5.9.2. 3D CNN model

Model trodimenzionalne konvolucijske neuronske mreže (3D CNN) predstavlja proširenje klasičnog modela konvolucijske neuronske mreže (CNN). Iako standardni CNN modeli efikasno obrađuju dvodimenzionalne podatke poput fotografija, 3D CNN posebno je dizajniran za obradu trodimenzionalnih podataka. Za razliku od klasičnog CNN-a koji koristi 2D konvolucije, 3D CNN koristi 3D konvolucijske filtre. Ova značajka omogućuje modelu da podatke osim po visini i širini, procesira (kao u 2D CNN-u) i po dubini, što može biti posebno korisno u obradi videozapisa ili sekvenci fotografija. Primjenom 3D konvolucija, 3D CNN može prepoznati složenije obrasce i informacije o pokretu koji se javljaju tijekom vremena. To ga čini vrlo efikasnim u analizi niza fotografija i u predviđanju vremenskih sekvenci (npr. predviđanje budućih slika u video sekvenci). Osnovna razlika između 3D CNN modela i hibridnog CNN-LSTM modela je u tome što 3D CNN model može detaljnije odrediti odnose unutar uzastopnih fotografija promatrane sekvence (u slučaju ovog modela, informacije za prethodnih 45 minuta), dok LSTM model koristeći dugotrajnu memoriju, osim informacija za prethodnih 45 minuta, istražuje i vremenski odnos svih dostupnih informacija.

Model 3D CNN sastoji se od dvije glavne komponente: 3D CNN-a za obradu slika u prostorno-vremenskoj domeni i dodatnog ulaza za informacije o trenutnoj razini izlazne snage fotonaponske elektrane. 3D CNN koristi trodimenzionalne konvolucije koje efikasno obrađuju informacije o

pokretu u sekvenci slika, dok dodatni ulaz služi za integraciju podataka o trenutnoj snazi elektrane. Kombinacija navedenih komponenti omogućuje modelu efikasno predviđanje buduće proizvodnje fotonaponske elektrane. Strukturu ovog modela može se vidjeti na slici 47.



Slika 47: Struktura razvijenog 3D CNN modela

Komponenta 3D CNN za obradu slika razvijena je s ciljem prepoznavanja značajki unutar niza fotografija koje su povezane s izlaznom snagom. Model se sastoji od sljedećih slojeva:

- Prvi konvolucijski sloj koristi 32 trodimenzionalna filtra veličine (3,3,3) te se služi ReLU aktivacijskom funkcijom;
- *MaxPooling* sloj veličine (2,2,2) konstruiran je zbog smanjenja dimenzionalnosti podataka i isticanja najutjecajnijih značajki;
- Drugi konvolucijski sloj koristi 64 trodimenzionalna filtra veličine (3,3,3) te se služi ReLU aktivacijskom funkcijom;

- Još jedan *MaxPooling* sloj veličine (2,2,2) implementiran je kako bi se dodatno smanjila dimenzionalnost podataka;
- *Flatten* sloj za pretvaranje višedimenzionalnog izlaza u jednodimenzionalni format;
- Sloj potpuno povezane neuronske mreže (eng. *Dense*) sa 128 jedinica i aktivacijskom funkcijom ReLU;
- *Dropout* sloj s omjerom ispadanja od 0,5, namijenjen sprječavanju pretreniranosti modela.

Model uključuje ulazni segment za izlaznu snagu, što mu omogućuje obrađivanje informacija o trenutnoj proizvodnji fotonaponskog sustava. Ovaj segment strukturiran je kroz ulazni sloj oblika (*n_input*), gdje "*n_input*" predstavlja broj ulaznih podatkovnih točaka - u ovom konkretnom modelu postavljen je na 45.

Integracija 3D CNN modela s navedenim dodatnim ulazom za informacije o trenutnoj razini snage ostvarena je preko sloja za spajanje (eng. *Concatenate layer*). Ovaj sloj za zadatak ima objediniti izlaze 3D CNN-a s dodatnim informacijama o izlaznoj snazi, stvarajući tako jedinstveni set podataka za daljnje korake obrade.

Završni sloj modela je sloj potpuno povezane neuronske mreže (eng. *Dense layer*) koji generira prognozu proizvodnje fotonaponske elektrane.

Za obuku modela potrebno je 1033 sekunde (17 minuta i 13 sekundi), što je 2.8 puta više vremena nego što je potrebno za obuku hibridnog CNN-LSTM modela. Ovaj aspekt predstavlja jedan od nedostataka - veliko vrijeme koje je potrebno za optimizaciju hiperparametara. Poveznica u navodu [117] omogućava pregled koda unutar Google Colab bilježnice.

5.10. Fino podešenje neuronske mreže na specijaliziranoj bazi podataka

Fino podešenje (eng. *fine-tuning*) je proces optimizacije prethodno obučenog modela neuronske mreže na novom, ali srodnom setu podataka. Umjesto izgradnje modela od nule, fino podešenje omogućuje korištenje spoznaja stečenih na jednom setu podataka u svrhu poboljšanja performansi


modela na drugom. U ovom istraživanju hibridni CNN-LSRM model treniran je na višegodišnjem setu podataka koji je opisan u poglavlju 5.3.1 i sadrži podatke prikupljane tijekom 497 dana.

U ovoj fazi istraživanja provedeno je fino podešavanje ranije navedene pred-trenirane neuronske mreže, i to koristeći specijaliziranu bazu podataka opisanu u poglavlju 5.3.2 koja je prilagođena zahtjevima predikcije izlazne snage fotonaponske elektrane Riteh 1. Specijalizirana baza podataka sadrži podatke prikupljene tijekom 44 dana. Cilj finog podešavanja je optimizirati model tako da precizno reflektira varijabilne uvjete koji su specifični za ovu elektranu, uključujući promjene u bazi uzrokovane meteorološkim uvjetima, sezonskim promjenama i lokalnim obilježjima.

5.11. Predviđanje buduće proizvodnje fotonaponske elektrane Riteh 1

Verifikacija modela izvodi se usporedbom prognoziranih i stvarno dobivenih podataka o izlaznoj snazi FNE Riteh 1. Ranije trenirana hibridna CNN-LSTM mreža koristi se za prognoziranje izlazne snage elektrane 15 minuta unaprijed. Mreža koristi ulazne podatke koji uključuju fotografije polusfere neba i informacije o sunčevom zračenju prikupljene modulom smještenim u neposrednoj blizini elektrane. Za potrebe analize, te se predikcije uspoređuju sa stvarnim vrijednostima izlazne snage FNE.

Na slici 48 prikazani su podaci koji se koriste za analitičku procjenu modela. Slika ilustrira dva seta vrijednosti: prvi set predstavlja podatke prikupljene pomoću modula smještenog u blizini elektrane, a drugi set sadrži stvarno izmjerene vrijednosti izlazne snage FNE Riteh 1.



Slika 48: Podaci korišteni za analitičku procjenu modela

U analizi izlazne snage fotonaponske elektrane i podataka o sunčevom zračenju prikupljenih na modulu na dan 27. kolovoza 2023., primijećena je znatna razlika u jutarnjim i večernjim satima. Ova bi odstupanja mogla utjecati na sposobnost predviđanja modela unutar tih perioda.

Iako se podaci uglavnom podudaraju tijekom dana, jutarnja snaga na fotonaponskoj elektrani je konzistentno niža od mjerenjima dobivenih na modulu. Odstupanje se može pripisati utjecaju okolišnih čimbenika, konkretno prisustvu visoke vegetacije istočno i zapadno od elektrane. Vegetacija djeluje kao prepreka i uzrokuje zasjenjivanje na solarnim panelima u jutarnjim satima, dok modul za prikupljanje podataka, koji se nalazi na povišenom položaju, ostaje neometan.

Tijekom dana kada je prisutna naoblaka (29. kolovoza 2023.), uočeno je smanjenje tih odstupanja. Ovaj fenomen može se objasniti difuznim karakterom sunčevog zračenja u oblačnim uvjetima. Kada je oblačno, sunčeve zrake su raspršene i dolaze iz više smjerova, što minimizira utjecaj zasjenjivanja uzrokovanog vegetacijom. U takvim uvjetima, i FNE i modul bilježe smanjenje intenziteta sunčevog zračenja.

6. REZULTATI PREDVIĐANJA BUDUĆE PROIZVODNJE FOTONAPONSKIH ELEKTRANA

Nakon što je razvoj i trening hibridnog CNN-LSTM modela uspješno proveden, slijedi evaluacija korištenjem testnog seta podataka. U ovom odjeljku predstavljaju se eksperimentalni rezultati i performanse modela u predviđanju proizvodnje fotonaponskih elektrana.

6.1. Pokazatelji točnosti rezultata

U svrhu sveobuhvatne procjene performansi modela dubokog učenja za kratkoročno predviđanje proizvodnje fotonaponskih elektrana koristi se više metrika evaluacije: Srednju apsolutnu pogrešku (eng. *mean absolute error*, MAE), korijen srednje kvadratne pogreške (eng. *root mean square error*, RMSE) i koeficijent determinacije (R^2).

Srednja apsolutna pogreška se koristi za kvantificiranje točnosti predviđanja modela kroz prosječnu apsolutnu razliku između stvarnih i predviđenih vrijednosti [118]. Ona pruža jasan i izravan pokazatelj točnosti modela i njegovu osjetljivost na pojedinačne pogreške:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_{predvideno} - P_{izmjereno}| \quad (5)$$

$P_{predvideno}$ je vrijednost izlazne snage predviđene modelom, $P_{izmjereno}$ stvarna vrijednost proizvodnje fotonaponske elektrane i N broj promatranih vrijednosti.

Korijen srednje kvadratne pogreške koristi se za mjerenje prosječne magnitude pogrešaka predviđanja [119]. Za razliku od MAE, RMSE daje veću težinu većim pogreškama zbog kvadriranja razlike, čineći ga posebno korisnim pri naglašavanju veće pogreške.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{forecasted} - P_{measured})^2} \quad (6)$$

Koeficijent determinacije (R^2) koristi se za procjenu koliko dobro model opisuje varijabilnost u ciljnom skupu podataka [120]. R^2 omogućuje da se kvantificira koliki dio varijance u stvarnoj proizvodnji elektrane može biti predviđen modelom.

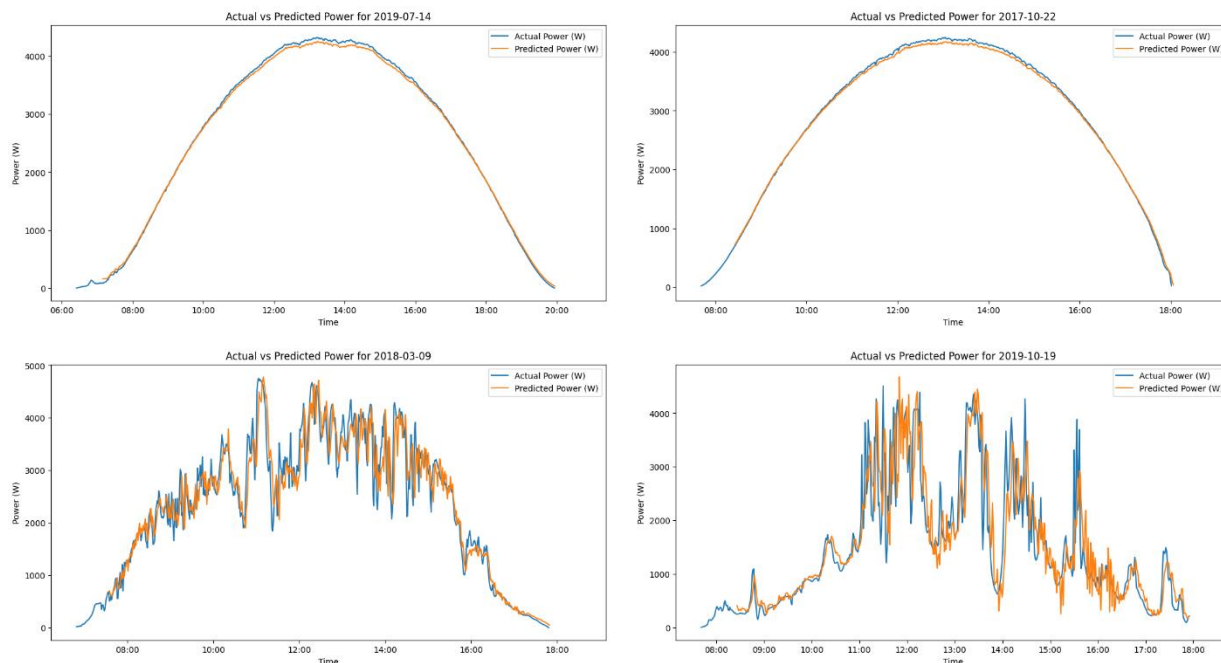
$$R^2 = 1 - \frac{\sum_{i=1}^N |P_{predvideno} - P_{izmjereno}|}{\sum_{i=1}^N |P_{predvideno} - \bar{P}_{izmjereno}|} \quad (7)$$

$P_{predvideno}$ vrijednost je izlazne snage predviđene modelom, $P_{izmjereno}$ stvarna vrijednost proizvodnje fotonaponske elektrane, N broj promatranih vrijednosti i $\bar{P}_{izmjereno}$ srednja vrijednost stvarnih vrijednosti proizvodnje fotonaponske elektrane.

Kombinirano, te tri vrijednosti pružaju sveobuhvatnu sliku performansi modela uključujući točnost predviđanja, osjetljivost na velike pogreške i sposobnost modela da objasni varijabilnost u podacima.

6.2. Evaluacija hibridnog CNN-LSTM modela


Modeli su podvrgnuti evaluaciji upotrebom skupa podataka koji obuhvaća 14003 fotografije polusfere neba uz pripadajuće informacije o proizvodnji fotonaponske elektrane. Skup za test sadrži podatke za ukupno dvadeset dana, uključujući deset sunčanih dana i deset pretežito oblačnih dana. Ova raznolikost omogućuje testiranje modela pod različitim uvjetima, od dana s relativno predvidljivom proizvodnjom energije do dana sa znatnim fluktuacijama u proizvodnji. Grafički prikazi za dva nasumično odabrana sunčana dana i dva nasumično odabrana oblačna dana iz testne skupine prikazani su na slici 49. Na grafu su ilustrirane stvarne proizvodnje fotonaponske elektrane te proizvodnje predviđene od strane modela.



Slika 49: Usporedna analiza stvarnih i predviđenih snaga fotonaponske elektrane za odabrane sunčane i pretežno oblačne dane

Rezultati modela prognoze pokazali su srednju apsolutnu pogrešku (MAE) od 499.36 i korijen srednje kvadratne pogreške (RMSE) od 714.06. Ove vrijednosti ističu efikasnost modela i relativno malo odstupanje od stvarnih vrijednosti. Efikasnost modela dodatno je potvrđena vrijednošću R^2 od 0.74, što sugerira da se približno 74% promatranih varijacija može objasniti ulaznim podacima modela.


Dijagram raspršenosti na slici 50 prikazuje usporedbu između stvarne i predviđene snage. Ova vizualizacija pobliže prikazuje odnos između ove dvije varijable, potvrđujući sposobnost modela da precizno predvidi izlaznu snagu fotonaponske elektrane.



Slika 50: Dijagram raspršenosti. Prikaz stvarne snage u odnosu na predviđenu izlaznu snagu fotonaponske elektrane

6.3. Evaluacija fino podešenog hibridnog CNN-LSTM modela


Razvijeni hibridni model fino je podešen s novom specijaliziranom bazom podatka koja sadrži podatke prikupljene tijekom 44 dana. Novi skup za test sadrži podatke za dodatnih šest dana, uključujući tri sunčana dana i tri pretežito oblačna dana. Grafički prikazi rezultata za jedan nasumično odabran sunčani dan i jedan nasumično odabran oblačan dan iz testne skupine prikazani su na slici 51. Na grafu su ilustrirane stvarne proizvodnje fotonaponske elektrane te proizvodnje predviđene od strane fino podešenog modela.



Slika 51: Usporedna analiza stvarnih i predviđenih snaga fino podešenim hibridnim CNN-LSTM modelom

Rezultati modela prognoze pokazali su srednju apsolutnu pogrešku (MAE) od 242.46 i korijen srednje kvadratne pogreške (RMSE) od 406.63. Ove vrijednosti ističu efikasnost modela i relativno malo odstupanje od stvarnih vrijednosti. Efikasnost modela dodatno je potvrđena vrijednošću R^2 od 0.78, što sugerira da se približno 78% promatranih varijacija može objasniti ulaznim podacima modela.


Dijagram raspršenosti na slici 52 prikazuje usporedbu između stvarne i predviđene snage dobivene fino podešenim modelom.



Slika 52: Dijagram raspršenosti. Prikaz stvarne snage u odnosu na predviđenu izlaznu snagu dobivenu fino podešenim hibridnim CNN-LSTM modelom

Za potrebe usporedbe novog fino podešenog modela s baznim modelom, bazni je model ponovno evaluiran na novim testnim podacima. Novi testni podaci sadrže informacije za samo šest dana, što dovodi do razlika u pokazateljima točnosti modela u odnosu na one prikazane u odlomku 6.2.

Na slici 53 prikazana je usporedba baznog modela i fino podešenog hibridnog CNN-LSTM modela. Analizirajući pokazatelje učinkovitosti, vidljivo je kako fino trenirani model ostvaruje bolje rezultate. Ovaj napredak ukazuje na uspješnu primjenu metode finog podešavanja i važnost ovog postupka za optimizaciju performansi modela u specifičnim uvjetima.




Slika 53: Usporedba baznog modela i fino podešenog hibridnog CNN-LSTM modela

6.4. Rezultati predviđanja buduće proizvodnje fotonaponske elektrane Riteh 1

Analiza rezultata predviđanja buduće proizvodnje FNE Riteh 1 provedena je usporedbom izlazne snage predviđene fino podešenim hibridnim CNN-LSTM modelom i informacija o stvarnoj izlaznoj snazi FNE. Grafički prikazi rezultata za dva odabrana dana prikazani su na slici 54.

Analiza rezultata predviđanja potvrđuje inicijalne pretpostavke iz odlomka 5.11 o utjecaju jutarnjih i večernjih odstupanja na performanse modela. Iako je model generalno efikasan u predviđanju izlazne snage fotonaponske elektrane tijekom dana, primijećena su znatna odstupanja u jutarnjim i

večernjim satima. Ova odstupanja prikazuju ograničenja modela u interpretaciji dinamike okolišnih čimbenika, poput zasjenjivanja uzrokovanog vegetacijom.




Slika 54: Usporedba stvarne izlazne snage FNE Riteh 1 i snage predviđene hibridnim CNN-LSTM modelom

Rezultati testiranja prognoze stvarne izlazne snage FNE Riteh 1 prikazani su u tablici 13. Analiza je provedena na potpunom testnom skupu, koji je sačinjen od podataka prikupljenih tijekom dva dana, te na svakom od tih dana pojedinačno: posebno za vedar dan i posebno za pretežno oblačan dan. Pojedinačne analize provedene su kako bi se utvrdila točnost modela u navedenim vremenskim uvjetima.

Tablica 13: Rezultati testiranja prognoziranja stvarne izlazne snage FNE Riteh 1

	MAE	RMSE	R ²
Oba dana	276	462	0.749
Vedar dan	118.4	185	0.955
Pretežno oblačan dan	400	632	0.548

Na slici Slika 55 prikazana su tri dijagrama raspršenosti, svaki za pojedini slučaj: vedar dan, pretežno oblačan dan i ukupni testni skup.




Slika 55: Dijagram raspršenosti: Prikaz stvarne snage FNE Riteh 1 u odnosu na predviđenu snagu; a) vedar dan, b) pretežno oblačan dan, c) ukupni testni skup

6.5. Usporedba s drugim modelima

Nakon što je 3D CNN mreža trenirana, iskorištena je za prognoziranje izlazne snage ranije opisanog testnog skupa. Rezultati testiranja prognoziranja modela su; srednja apsolutna pogreška (MAE) od 513.37 i korijen srednje kvadratne pogreške (RMSE) od 725.46. Ove metrike


naglašavaju učinkovitost modela i relativno malu devijaciju od stvarnih vrijednosti. Učinkovitost modela dalje se potvrđuje koeficijentom determinacije R^2 od 0.73, sugerirajući da se oko 73% promatranih varijacija može objasniti ulaznim podacima modela.

Dijagram raspršenosti prikazan na slici 56 prikazuje usporedbu stvarne snage i snage prognozirane 3D CNN modelom. Ova vizualizacija dodatno objašnjava veze između ove dvije varijable, potvrđujući preciznost modela u prognozi izlazne snage fotonaponske elektrane.



Slika 56: Dijagram raspršenosti: Prikaz stvarne snage u odnosu na predviđenu izlaznu snagu fotonaponske elektrane uporabom 3D CNN modela

Na slici 57 prikazana je usporedba između 3D CNN i hibridnog CNN-LSTM modela. Analizirajući pokazatelje učinkovitosti, vidljivo je kako oba modela postižu slične rezultate. Međutim, ključna je razlika vrijeme potrebno za trening svakog modela. Hibridni CNN-LSTM model pokazuje se znatno bržim u ovom aspektu.



Slika 57: Usporedba 3D CNN i hibridnog CNN-LSTM modela

Ovaj rezultat može imati značajne praktične implikacije. Manje vremena potrebno za trening modela rezultira bržim iteracijama i prilagodbama modela, a što je posebno korisno u dinamičnim operativnim okruženjima kao što su fotonaponske elektrane. Dakle, iako oba modela postižu slične performanse u pogledu točnosti predviđanja, hibridni CNN-LSTM model pruža dodatnu prednost u polju učinkovitosti i brzine.

Uzimajući u obzir modele trenirane s većom bazom ulaznih podataka, razlika u točnosti između modela može biti veća, pri čemu hibridni CNN-LSTM model može pokazivati superiornije rezultate. Ova prednost uglavnom se može pripisati dugoročnoj memoriji koju posjeduje LSTM komponenta modela, koja je sposobna otkrivati i učiti iz sezonskih obrazaca prisutnih u podacima.

6.6. Evaluacija utjecaja duljine ulaznih podataka na kratkoročne predikcije proizvodnje fotonaponskih elektrana

LSTM model inherentno bilježi proizvodne obrasce koji uključuju godišnje, mjesečne i dnevne cikluse. Točna priroda ovih obrazaca unutar modela može biti nedokučiva jer se model dinamički prilagođava, razvija i povezuje obrasce koji se smatraju najrelevantnijima za postizanje vrlo


preciznih predviđanja. Važno je naglasiti da svaka nova iteracija treninga modela može dovesti do drugačijih rezultata. Ova varijabilnost je posljedica stohastičkih prilagodbi napravljenih na modelu tijekom obuke, što rezultira jedinstvenim modelima nakon svakog procesa obuke.

Osim ugrađenih obrazaca proizvodnje električne energije, model koristi nizove fotografija snimljenih neposredno prije generiranja novih prognoza proizvodnje fotonaponskih elektrana. Model koristi te fotografije za otkrivanje promjena u naoblaci neposredno prije prognoze. Spajanjem ovih promatranih promjena s postojećim obrascima proizvodnje, model predviđa buduću proizvodnju električne energije.

Kako bi se kvantificirali učinci različitih duljina ulaznih nizova fotografija potrebnih za predviđanje, modeli su trenirani sekvencijalno koristeći različite duljine ulaznih nizova. Svi ostali parametri modela ostali su konstantni kako bi se minimizirao bilo kakav učinak koji bi mogli imati na rezultate. Parametri za sve modele ispitane u ovoj analizi uključuju: broj epoha: 5, veličinu serije: 32 i optimizator: adam.


U analizi opisanoj u ovom odjeljku, promijenjena je duljina ulaznih podataka, korišteni su vremenski intervali od 15, 30, 45, 60, 75, 90, 105 i 120 minuta. Ove vrijednosti istovremeno predstavljaju i broj ulaznih fotografija i odgovarajući vremenski okvir za ulazne podatke kao što je prikazano na slici 58.

Duljina ulaznog niza fotografija povećava očnost modela. Dulji niz fotografija omogućuje modelu potpunije razumijevanje uvjeta oblaka prije predviđenog vremena proizvodnje. Međutim, duljina niza donosi i određene nedostatke. Na primjer, ako je potrebna duljina niza fotografija za predviđanje postavljena na dva sata, nemoguće je predvidjeti prva dva sata proizvodnje u danu pomoću ove metode, kao što je prikazano na slici 59. Stoga, odabir broja fotografija koje model koristi kao ulazne podatke mora biti pažljivo izbalansiran kako bi se održala praktičnost modela bez ugrožavanja željene točnosti predviđanja.



Slika 58: Utjecaj duljine ulaznih podataka na točnost predviđanja

Nadalje, kako se broj ulaznih fotografija povećava zahtjevi za računalnim resursima rastu, utječući ne samo na fazu obuke modela, već i na predviđanje. To produžuje vrijeme potrebno za predviđanje buduće proizvodnje. Važno je naglasiti da se vrijeme treninga modela također značajno povećava kada veći broj fotografija čini ulaznu sekvencu modela. Primjerice, na računaru na kojem je model treniran vrijeme izračuna za jedno predviđanje moglo bi biti zanemarivo. Međutim, ako se unutar sustava predviđanja koristi manje sofisticirano i isplativo računalo, kao što je Raspberry Pi, vrijeme potrebno za predviđanje može postati značajan faktor.




Slika 59: Utjecaj duljine ulaznih podataka na predviđanje: nemogućnost predviđanja za prva dva sata proizvodnje kod uporabe modela s duljinom ulazne sekvence fotografija od dva sata

6.7. Evaluacija utjecaja vremenske rezolucije ulaznih podataka na točnost modela

Vremenska rezolucija ulaznih podataka ključan je faktor koji utječe na točnost bilo kojeg prediktivnog modela. Posebno je to važno prilikom određivanja frekvencije uzorkovanja fotografija nebeske polusfere na lokaciji FNE. Vremenska rezolucija ne utječe samo na brzinu obrade podataka, već i na količinu memorije potrebne za pohranu sveobuhvatne baze podataka. U ovom radu provedena je analiza procjene utjecaja različitih vremenskih rezolucija ulaznih podataka na točnost modela. Model je posebno testiran koristeći ulazne podatke s vremenskom rezolucijom od 1 minute, 5 minuta i 15 minuta.

Tijekom modifikacije vremenske rezolucije ulaznih podataka, svi ostali parametri unutar modela zadržani su konstantnima. Ovaj pristup osigurao je da se sve varijacije u točnosti modela mogu


izravno pripisati promjenama u vremenskoj rezoluciji. Smanjenje vremenske rezolucije ulaznih podataka rezultira smanjenjem količine podataka za trening, a što rezultira znatno kraćim vremenom treninga u usporedbi s izvornim modelom. Vremena treninga za mrežu i druge metrike evaluacije performansi prikazane su na slici 60.



Slika 60: Performanse modela pri različitim vremenskim rezolucijama ulaznih podataka

Ovi rezultati ističu ključnu ulogu vremenske rezolucije ulaznih podataka u efikasnosti prediktivnih modela, pružajući nezamjenjive upute za njihovu prilagodbu u praktičnom okruženju. Identificiranjem ovog bitnog odnosa između vremenske rezolucije i preciznosti modela, otvorena su vrata za daljnja unapređenja u modeliranju. Ovime se daje jasna putanja za buduće modifikacije i inovativne pristupe u području prediktivnih modela za proizvodnju solarne energije. Također, značajno je napomenuti da smanjenjem vremenske rezolucije ulaznih podataka, dok se postiže brži trening modela, raste i mogućnost povećanja greške modela. Ovaj aspekt dodatno naglašava složenost i važnost optimalnog odabira vremenske rezolucije za precizno i efikasno modeliranje.

Slika 61 prikazuje rezultate predikcije za određeni dan iz skupa testnih podataka i ilustrira utjecaj rezolucije podataka na mogućnost predviđanja brzih promjena u proizvodnji fotonaponske elektrane tijekom pretežito oblačnih dana. Ovakvi uvjeti mogu u velikoj mjeri pridonijeti smanjenju točnosti modela.



Slika 61: Usporedba stvarne i predviđene proizvodnje fotonaponskih elektrana tijekom pretežito oblačnih dana; a) rezolucija ulaznih podataka: 5 min; b) rezolucija ulaznih podataka: 15 min

6.8. Evaluacija utjecaja horizonta prognoze na kratkoročne predikcije proizvodnje fotonaponskih elektrana


Horizont prognoze modela igra ključnu ulogu u njegovoj praktičnoj primjeni. Primarni fokus ovog rada je kratkoročna prognoza, posebno usmjeren na horizont prognoze od 15 minuta u budućnost. Izvršena je detaljna analiza kako bi se procijenila učinkovitost modela na različitim horizontima prognoze te utvrdilo može li se model prilagoditi za različite vrste zadataka, kao što su dugoročne ili ultra-kratkoročne prognoze.

Prilikom testiranja različitih horizonta prognoze, svi parametri modela zadržani su na određenim vrijednostima osim horizonta prognoze izraženog u minutama. Tako su razvijeni modeli za prognostičke horizonte od 1, 5, 10, 15, 20, 25, 30 i 35 minuta unaprijed.

Vrijeme potrebno za trening modela pokazuje neznatnu varijabilnost ovisno o horizontu prognoze. U prosjeku, trening modela s različitim horizontima prognoze traje oko 364 sekunde, što je otprilike 6 minuta i 4 sekunde.

Slika 62 prikazuje rezultate analize modela s testnim setom podataka, ilustrirajući utjecaj horizonta prognoze na preciznost modela kratkoročnog predviđanja izlazne snage fotonaponskih elektrana. Ova analiza pruža vrijedne informacije o tome kako promjena horizonta prognoze utječe na točnost

predviđanja modela, što je ključno za optimalno usklađivanje modela s određenim potrebama i uvjetima.



Slika 62: Analiza modela s različitim horizontima predviđanja

Analiza predstavljena u ovom radu otkriva promjenu točnosti modela kratkoročne prognoze proizvodnje fotonaponskih elektrana u odnosu na različite horizonte predviđanja. Ova su zapažanja posebno korisna jer doprinose dubljem razumijevanju utjecaja horizonta prognoze na performanse modela, otvarajući put za njegovu učinkovitiju implementaciju.

Iz navedenih rezultata vidi se da su performanse modela povezane s kompleksnošću vremenskih uvjeta. U usporedbi s ultra-kratkoročnim prognozama, dugoročne prognoze mogu biti izazovnije zbog povećane vjerojatnosti nepredvidljivih promjena vremenskih uvjeta.

6.9. Diskusija rezultata modela za predviđanje buduće proizvodnje fotonaponskih elektrana

Rezultati potvrđuju izuzetnu učinkovitost hibridnog CNN-LSTM modela u predviđanju rada fotonaponskih elektrana. Ovaj model iskorištava sposobnost otkrivanja značajki u nizu fotografija polusfere neba i uzoraka iz podataka o izlaznoj snazi fotonaponske elektrane kako bi predvidio buduću proizvodnju fotonaponske elektrane. Integracija CNN i LSTM modela omogućuje kompetentno izdvajanje prostornih i vremenskih obrazaca iz ulaznih podataka, osiguravajući iznimne performanse.

Mjerni podaci predloženog hibridnog modela - srednja apsolutna pogreška (MAE), korijen srednje kvadratne pogreške (RMSE) i koeficijent determinacije (R^2) - pokazuju visoku korelaciju između stvarne i predviđene izlazne snage, ukazujući tako na visoku točnost predviđanja.

Spoj CNN-a i LSTM-a u modelu predviđanja proizvodnje fotonaponske energije predstavlja značajan napredak u točnosti i praktičnosti. Ovaj model uključuje korištenje fotografija niske rezolucije i podataka o proizvodnji elektrane za izradu točnih prognoza. Primjena ovog modela može se proširiti na različite vrste solarnih elektrana te eliminira potrebu za skupim piranometrima ili kompliciranim sustavima za dobivanje fotografija, smanjujući tako investicijske troškove. Međutim, ovaj model dubokog učenja zahtijeva opsežan skup podataka za obuku, što bi mogao biti izazov u slučajevima kada je dostupnost podataka ograničena. Osim toga, model se mora prilagoditi za svaku novu lokaciju kako bi se osigurala optimalne performanse, što znači da se ne može primijeniti na svakoj elektrani bez prethodnih prilagodbi i optimizacija.

Korištenjem tehnike finog podešavanja modela, uspješno je povećana točnost predikcije u realnim operativnim uvjetima. Ova faza istraživanja ključna je za osiguranje da model nije samo teorijski utemeljen, već i praktično primjenjiv na specijaliziranim podatkovnim skupovima.

Odjeljak o utjecaju vremenske rezolucije ulaznih podataka na točnost modela ističe ključnu ulogu koju odabir vremenske rezolucije ima u razvoju prediktivnih modela za proizvodnju fotonaponske energije. Istraživanje pokazuje da viša rezolucija može učinkovito pratiti brze promjene u snazi izlazne energije tijekom pretežito oblačnih dana, poboljšavajući točnost modela. Međutim,

kompromis između poboljšane točnosti koju pružaju podaci visoke rezolucije i povećanih računalnih zahtjeva potrebnih za njezino postizanje, ključno je pitanje za razmatranje, posebno u scenarijima s ograničenim resursima. Smanjenje vremenske rezolucije jedna je od mogućih strategija za smanjenjem potreba za računalnom snagom, ali to može ugroziti sposobnost modela da precizno prati brze promjene u izlaznoj snazi. Ova otkrića ključna su za razumijevanje odnosa između rezolucije ulaznih podataka i performansi modela te će pomoći u optimizaciji budućih prediktivnih modela.

Pri ocjenjivanju utjecaja duljine ulaznog niza fotografija uočeno je kako nema značajnog učinka na točnost modela. Što je više fotografija dodano nizu, model postaje detaljniji, omogućujući mu bolje predstavljanje uvjeta u stvarnom svijetu. Međutim, model koji uključuje veći broj fotografija u svom ulaznom nizu također predstavlja i određene izazove. Osim poboljšanja točnosti, uzeto je u obzir i vrijeme potrebno za treniranje različitih modela. Kako se broj ulaznih fotografija povećava, tako se proporcionalno povećava i vrijeme treniranja. Stoga, kompromis između točnosti, vremena i računalnih zahtjeva treba uzeti u obzir tijekom izgradnje modela.

Drugi aspekt analize je utjecaj različitih horizonata prognoze na točnost prognoze. Utvrđeno je da produljenje horizonta prognoze može povećati pogrešku prognoze. Takav slučaj potencijalna je posljedica inherentne nepredvidljivosti atmosferskih uvjeta, nasumične prirode stvaranja oblaka i raspršivanja unutar kratkih vremenskih intervala, te različite brzine i smjera kretanja oblaka na različitim visinama.

7. ZAKLJUČAK

Rastući udio obnovljivih izvora energije u strukturi proizvodnih jedinica energetskog sektora dovodi i do izazova koji proizlaze iz varijabilnosti i nepredvidljivosti obnovljivih izvora. Kao moguće rješenje, ovaj rad analizira i prikazuje napredne metode kratkoročnog predviđanja proizvodnje fotonaponskih elektrana. Uvođenje dubokog učenja u obliku konvolucijskih neuronskih mreža i dugotrajne kratkoročne memorije omogućuje visoku točnost predviđanja i služi boljem razumijevanju kompleksnih odnosa između vremenskih uvjeta i buduće proizvodnje električne energije. Osim metode kratkoročnog predviđanja, razvijen je i sustav za efikasno prikupljanje i obradu fotografija.

U radu je razvijen i evaluiran hibridni CNN-LSTM model za predviđanje izlazne snage fotonaponske elektrane na temelju fotografija polusfere neba i podataka o izlaznoj snazi. Kombinacija CNN-a i LSTM-a omogućila je učinkovito učenje prostornih i vremenskih obrazaca iz ulaznih podataka, a što je rezultiralo poboljšanom izvedbom u usporedbi s pojedinačnim modelima. Unatoč visokoj točnosti osnovnog hibridnog modela, izvršena je i daljnja optimizacija, posebice s obzirom na podatke prikupljene direktno na lokaciji fotonaponske elektrane Riteh 1.

Jedna od tih optimizacijskih mjera je i fino podešenje pred-treniranog modela, specifično usmjerenog na podatke prikupljene na lokaciji stvarne fotonaponske elektrane, s ciljem dodatnog povećanja točnosti predviđanja buduće proizvodnje. Primjenom fino podešenja na pred-treniranom modelu na podacima prikupljenim direktno na lokaciji fotonaponske elektrane, postignuto je značajno poboljšanje točnosti predviđanja. Ovaj postupak fino podešenja osigurava da model ne samo dobro generalizira na novim podacima, već i efikasno kapitalizira na prethodno naučenim značajkama, čime se dodatno poboljšavaju njegove performanse u realnim uvjetima korištenja.

Model je široko primjenjiv u stvarnom svijetu kao dio fotonaponskih elektrana i elektroenergetskih sustava. Točne prognoze proizvodnje fotonaponskih elektrana mogu pomoći operaterima sustava da planiraju i upravljaju opterećenjem i proizvodnjom, smanje troškove i poboljšaju ukupnu učinkovitost sustava. Osim toga, model pridonosi boljoj integraciji fotonaponskih elektrana u elektroenergetsku mrežu, smanjujući ovisnost o skupim i ekološki manje prihvatljivim elektranama koje se koriste kao rezerva snage.

Kroz provedeno istraživanje uspješno su ostvareni postavljeni ciljevi. Razvijen je model za kratkoročno predviđanje proizvodnje fotonaponskih elektrana, temeljen na konvolucijskoj neuronskoj mreži koja je trenirana sukcesivnim nizom fotografija polusfere neba. Također, izrađena je referentna baza podataka fotografija polusfere neba i popratnih meteoroloških uvjeta, kao i testni poligon za verifikaciju i evaluaciju točnosti predviđanja predloženog modela te usporedbu s drugim modelima.

Postavljena hipoteza koja tvrdi da se uporabom baze podataka s visokom vremenskom rezolucijom može povećati točnost modela za kratkoročno predviđanje proizvodnje fotonaponskih elektrana, potvrđena je kroz ovaj rad. Primjenom razvijenog modela i referentne baze podataka postignuta je visoka razina točnosti u predviđanju proizvodnje, čime je unaprijeđena strategija planiranja i optimizacija u fotonaponskim elektranama.

Znanstveni doprinos ovog istraživanja očituje se prvenstveno u razvoju modela za kratkoročno predviđanje proizvodnje fotonaponskih elektrana. Osim toga, doprinos je i u obliku referentne baze podataka i testnog poligona koji omogućuju daljnja istraživanja i evaluacije. Naposljetku, razvijeni model i metodologija nude značajan potencijal za primjenu u stvarnim elektroenergetskim sustavima, omogućujući tako bolje planiranje i učinkovito upravljanje resursima.

Daljnja istraživanja usredotočit će se na poboljšanje performansi modela integracijom dodatnih podataka, kao što su podaci o proizvodnji iz drugih obnovljivih izvora energije ili podaci o potrošnji električne energije. Ovo istraživanje uključivat će razvoj novih metoda za procjenu i minimiziranje nesigurnosti prognoze s ciljem poboljšanja primjenjivosti na terenu. Model bi također mogao imati koristi i od korištenja fotografija visoke razlučivosti kao ulaznih podataka. Ovakav bi pristup omogućio uključivanje dodatnih CNN slojeva sposobnih za obradu ulaznih fotografija s više detalja, što bi vjerojatno rezultiralo daljnjim povećanjem točnosti predviđanja.

Zaključno, ovaj je rad primjer kako duboko učenje može doprinijeti napretku u području obnovljivih izvora energije. Dok se modeli dubokog učenja već neko vrijeme naširoko koriste u drugim sektorima, njihova primjena u kontekstu fotonaponskih elektrana i elektroenergetskih sustava još uvijek je relativno nova. U skladu s tehnološkim napretkom, predviđa se kontinuirani rast ovog područja.

Literatura

- [1] Stern, D. I., *Economic growth and energy*, Encyclopedia of energy, 2(00147), 35-51, 2004.
- [2] Kikstra, J. S., Nicholls, Z. R., Smith, C. J., Lewis, J., Lamboll, R. D., Byers, E., ... & Riahi, K., *The IPCC Sixth Assessment Report WGIII climate assessment of mitigation pathways: from emissions to global temperatures*, Geoscientific Model Development, 15(24), 9075-9109, 2022.
- [3] U. (. N. F. C. o. C. Change), *Adoption of the Paris Agreement*, UNFCCC. FCCC/CP/2015/L.9/Rev. 1, 2015.
- [4] Panwar, N. L., Kaushik, S. C., & Kothari, S., *Role of renewable energy sources in environmental protection: A review*, Renewable and sustainable energy reviews, 15(3), 1513-1524, 2011.
- [5] *EEA greenhouse gases — data viewer: Synthesis*, European Environment Agency (EEA), DAS-270-en, 2021.
- [6] A. Qazi, F. Hussain, N.A. Rahim, G. Hardaker, D. Alghazzawi, K. Shaban, & K. Haruna, *Towards sustainable energy: a systematic review of renewable energy sources, technologies, and public opinions*, IEEE access, 7, 63837-63851, 2019.
- [7] Murdock, Hannah E., et al., *Renewables 2021-global status report*, 2021.
- [8] Kumar, Varun, A. S. Pandey, and S. K. Sinha., *Grid integration and power quality issues of wind and solar energy system: A review*, International conference on emerging trends in electrical electronics & sustainable energy systems (ICETEESES). IEEE, 2016.
- [9] Impram, S., Nese, S. V., & Oral, B., *Challenges of renewable energy penetration on power system flexibility: A survey*, Energy Strategy Reviews, 31, 100539, 2020.
- [10] Infield, D., & Freris, L., *Renewable energy in power systems*, John Wiley & Sons, 2020.

- [11] Anvari, M. et al., *Short term fluctuations of wind and solar power systems. New Journal of Physics 18, 063027, 2016.*, New Journal of Physics 18, 063027, 2016.
- [12] Akhter, M. N., Mekhilef, S., Mokhlis, H., & Mohamed Shah, N., *Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques*, IET Renewable Power Generation, 13(7), 1009-1023, 2019.
- [13] G. e. Boyle, *Renewable electricity and the grid: The challenge of variability*, London, UK: Earthscan Publications Ltd., 2012.
- [14] S. Jenniches, *Assessing the regional economic impacts of renewable energy sources – A literature review*, Renewable and Sustainable Energy Reviews, Volume 93, Pages 35-51, ISSN 1364-0321, 2018.
- [15] Chaturvedi, D. K., & Isha, I., *Solar power forecasting: A review*, International Journal of Computer Applications, 145(6), 28-50, 2016.
- [16] Yang, B., Zhu, T., Cao, P., Guo, Z., Zeng, C., Li, D., ... & Yu, T., *Classification and summarization of solar irradiance and power forecasting methods: A thorough review*, CSEE Journal of Power and Energy Systems, 2021.
- [17] U. & W. Z. Munawar, *A framework of using machine learning approaches for short-term solar power forecasting*, Journal of Electrical Engineering & Technology, 15(2), 561-569, 2020.
- [18] Wu, C., Zhang, X. P., & Sterling, M., *Solar power generation intermittency and aggregation*, Scientific Reports, 12(1), 1363, 2022.
- [19] Järvelä, M., Lappalainen, K., & Valkealahti, S., *Characteristics of the cloud enhancement phenomenon and PV power plants*, Solar Energy, 196, 137-145, 2020.
- [20] Wang, F., Mi, Z., Su, S. and Zhao, H., *Short-term solar irradiance forecasting model based on artificial neural network using statistical feature parameters*, Energies, 5(5), pp.1355-1370, 2012.

- [21] Sivaneasan, B., Yu, C.Y. and Goh, K.P., *Solar forecasting using ANN with fuzzy logic pre-processing*, Energy procedia, 143, pp.727-732, 2017.
- [22] Wentz, V.H., Maciel, J.N., Gimenez Ledesma, J.J. and Ando Junior, O.H., *Solar Irradiance Forecasting to Short-Term PV Power: Accuracy Comparison of ANN and LSTM Models*, Energies, 15(7), p.2457, 2022.
- [23] Sharma, J., Soni, S., Paliwal, P., Saboor, S., Chaurasiya, P.K., Sharifpur, M., Khalilpoor, N. and Afzal, A., *A novel long term solar photovoltaic power forecasting approach using LSTM with Nadam optimizer: A case study of India*, Energy Science & Engineering, 10(8), pp.2909-2929, 2022.
- [24] Yu, Y., Cao, J. and Zhu, J., *An LSTM short-term solar irradiance forecasting under complicated weather conditions*, IEEE Access, 7, pp.145651-145666, 2019.
- [25] Oh, M., Kim, C.K., Kim, B., Yun, C., Kang, Y.H. and Kim, H.G., *Spatiotemporal optimization for short-term solar forecasting based on satellite imagery*, Energies, 14(8), p.2216, 2021.
- [26] Cheng, L., Zang, H., Wei, Z., Ding, T., Xu, R., & Sun, G., *Short-term solar power prediction learning directly from satellite images with regions of interest*, IEEE Transactions on Sustainable Energy, 13(1), 629-639, 2021.
- [27] Miller, S.D., Rogers, M.A., Haynes, J.M., Sengupta, M. and Heidinger, A.K., *Short-term solar irradiance forecasting via satellite/model coupling*, Solar Energy, 168, pp.102-117, 2018.
- [28] Ryu, A., Ito, M., Ishii, H., & Hayashi, Y., *Preliminary analysis of short-term solar irradiance forecasting by using total-sky imager and convolutional neural network*, 2019 IEEE PES GTD Grand International Conference and Exposition Asia, 2019.
- [29] Feng, C., Zhang, J., Zhang, W., & Hodge, B. M., *Convolutional neural networks for intra-hour solar forecasting based on sky image sequences*, Applied Energy, 310, 118438, 2022.

- [30] Sharafati, A., Khosravi, K., Khosravinia, P., Ahmed, K., Salman, S. A., Yaseen, Z. M., & Shahid, S., *The potential of novel data mining models for global solar radiation prediction*, International Journal of Environmental Science and Technology, 16, 2019.
- [31] Kim S-G, Jung J-Y, Sim MK., *A Two-Step Approach to Solar Power Generation Prediction Based on Weather Data Using Machine Learning*, Sustainability; 11(5):1501, 2019.
- [32] T. AlSkaif, S. Dev, L. Visser, M. Hossari, & W. van Sark, *A systematic analysis of meteorological variables for PV output power estimation*, Renewable Energy, 153, 12-22, 2020.
- [33] West, S.R., Rowe, D., Sayeef, S. and Berry, A., *Short-term irradiance forecasting using skycams: Motivation and development*, Solar Energy, 110, pp.188-207, 2014.
- [34] H. Huang, J. Xu, Z. Peng, S. Yoo, D. Yu, D. Huang, & H. Qin, *Cloud motion estimation for short term solar irradiation prediction*, IEEE International Conference on Smart Grid Communications (SmartGridComm) (pp. 696-701). IEEE, 2013.
- [35] Zou, Kelly H., Kemal Tuncali, and Stuart G. Silverman., *Correlation and simple linear regression*, Radiology 227.3: 617-628, 2003.
- [36] Ahmed, R., Sreeram, V., Mishra, Y., & Arif, M. D., *A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization*, Renewable and Sustainable Energy Reviews, 124, 109792, 2020.
- [37] Zhou, Y., Dong, H., & El Saddik, A., *Deep learning in next-frame prediction: A benchmark review*, IEEE Access, 8, 69273-69283, 2020.
- [38] Dissawa, D.M.L.H., Ekanayake, M.P.B., Godaliyadda, G.M.R.I., Ekanayake, J.B. and Agalgaonkar, A.P., *Cloud motion tracking for short-term on-site cloud coverage prediction*, In 2017 Seventeenth International Conference on Advances in ICT for Emerging Regions (ICTer) (pp. 1-6). IEEE, 2017.

- [39] Nie, Y., Li, X., Paletta, Q., Aragon, M., Scott, A., & Brandt, A., *Open-Source Ground-based Sky Image Datasets for Very Short-term Solar Forecasting, Cloud Analysis and Modeling: A Comprehensive Survey*, arXiv preprint arXiv:2211.14709, 2022.
- [40] Jakoplić, A., Franković, D., Kirinčić, V. and Plavšić, T., *Benefits of short-term photovoltaic power production forecasting to the power system*, Optimization and Engineering, 22, pp.9-27., 2021.
- [41] Catalão, J.P. ed., *Electric power systems: advanced forecasting techniques and optimal generation scheduling*, CRC press, 2017.
- [42] Enslin, J.H., *Network impacts of high penetration of photovoltaic solar power systems*, In IEEE PES General Meeting (pp. 1-5). IEEE, 2010.
- [43] Widén, J., Wäckelgård, E., Paatero, J. and Lund, P., *Impacts of distributed photovoltaics on network voltages: Stochastic simulations of three Swedish low-voltage distribution grids*, Electric power systems research, 80(12), pp.1562-1571, 2010.
- [44] Mulenga, E., *Impacts of integrating solar PV power to an existing grid. Case Studies of Mölndal and Orust energy distribution (10/0.4 kV and 130/10 kV) grids*, 2015.
- [45] Iheanetu, K.J., *Solar Photovoltaic Power Forecasting: A Review*, Sustainability, 14(24), p.17005, 2022.
- [46] Taylor, J.W., *Triple seasonal methods for short-term electricity demand forecasting*, European Journal of Operational Research, 204(1), pp.139-152, 2010.
- [47] Lago, J., De Ridder, F., Vranx, P. and De Schutter, B., *Forecasting day-ahead electricity prices in Europe: The importance of considering market integration*, Applied energy, 211, pp.890-903, 2018.
- [48] Foley, A.M., Leahy, P.G., Marvuglia, A. and McKeogh, E.J., *Current methods and advances in forecasting of wind power generation*, Renewable energy, 37(1), pp.1-8, 2012.

- [49] Perez, R., Ineichen, P., Moore, K., Kmiecik, M., Chain, C., George, R. and Vignola, F., *A new operational model for satellite-derived irradiances: description and validation*, Solar Energy, 73(5), pp.307-317, 2002.
- [50] Amjady, N. and Hemmati, M., *Energy price forecasting-problems and proposals for such predictions*, IEEE Power and Energy Magazine, 4(2), pp.20-29, 2006.
- [51] Dolara, A., Grimaccia, F., Leva, S., Mussetta, M. and Ogliari, E., *A physical hybrid artificial neural network for short term forecasting of PV plant power output*, Energies, 8(2), pp.1138-1153, 2015.
- [52] Perez, R., Lorenz, E., Pelland, S., Beauharnois, M., Van Knowe, G., Hemker Jr, K., Heinemann, D., Remund, J., Müller, S.C., Traunmüller, W. and Steinmayer, G., *Comparison of numerical weather prediction solar irradiance forecasts in the US, Canada and Europe*, Solar Energy, 94, pp.305-326, 2013.
- [53] Urquhart, B., Kurtz, B., Dahlin, E., Ghonima, M., Shields, J.E. and Kleissl, J., *Development of a sky imaging system for short-term solar power forecasting*, Atmospheric Measurement Techniques, 8(2), pp.875-890, 2015.
- [54] Blanc, P., Remund, J. and Vallance, L., *Short-term solar power forecasting based on satellite images*, In Renewable energy forecasting (pp. 179-198). Woodhead Publishing, 2017.
- [55] Wang, G., Su, Y. and Shu, L., *One-day-ahead daily power forecasting of photovoltaic systems based on partial functional linear regression models*, Renewable Energy, 96, pp.469-478, 2016.
- [56] Benali, L., Notton, G., Fouilloy, A., Voyant, C. and Dizene, R., *Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components*, Renewable energy, 132, pp.871-884, 2019.

- [57] Niu, D., Wang, K., Sun, L., Wu, J. and Xu, X., *Short-term photovoltaic power generation forecasting based on random forest feature selection and CEEMD: A case study*, Applied soft computing, 93, p.106389, 2020.
- [58] Kudo, M., Takeuchi, A., Nozaki, Y., Endo, H. and Sumita, J., *Forecasting electric power generation in a photovoltaic power system for an energy network*, Electrical Engineering in Japan, 167(4), pp.16-23, 2009.
- [59] Abdel-Nasser, M. and Mahmoud, K., *Accurate photovoltaic power forecasting models using deep LSTM-RNN*, Neural Computing and Applications, 31, pp.2727-2740, 2019.
- [60] Wood-Bradley, P., Zapata, J. and Pye, J., *Cloud tracking with optical flow for short-term solar forecasting*, 2012.
- [61] Schmidt, T., Calais, M., Roy, E., Burton, A., Heinemann, D., Kilper, T. and Carter, C., *Short-term solar forecasting based on sky images to enable higher PV generation in remote electricity networks*, Renewable Energy and Environmental Sustainability, 2, p.23, 2017.
- [62] Tiwari, S., Sabzehgar, R. and Rasouli, M., *Short term solar irradiance forecast using numerical weather prediction (NWP) with gradient boost regression*, In 2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG) (pp. 1-8). IEEE, 2018.
- [63] Kandasamy, C.P., Prabu, P. and Niruba, K., *Solar potential assessment using PVSYST software*, In 2013 International Conference on Green Computing, Communication and Conservation of Energy (ICGCE) (pp. 667-672). IEEE, 2013.
- [64] Abdallah, R., Juaidi, A., Salameh, T., Jeguirim, M., Çamur, H., Kassem, Y. and Abdala, S., *Estimation of solar irradiation and optimum tilt angles for south-facing surfaces in the United Arab Emirates: A case study using PVGIS and PVWatts*, In Recent advances in renewable energy technologies (pp. 3-39). Academic Press, 2022.

- [65] Kenny, R.P., Huld, T.A. and Iglesias, S., *Energy rating of PV modules based on PVGIS irradiance and temperature database*, In Proceedings from 21st European Photovoltaic Solar Energy Conference and Exhibition (pp. 4-8), 2006.
- [66] Sharma, R. and Gidwani, L., *Grid connected solar PV system design and calculation by using PV SOL premium simulation tool for campus hostels of RTU Kota*, In 2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT) (pp. 1-5). IEEE, 2017.
- [67] Umar, N., Bora, B., Banerjee, C. and Panwar, B.S., *Comparison of different PV power simulation softwares: case study on performance analysis of 1 MW grid-connected PV solar power plant*, International Journal of Engineering Science Invention (IJESI), 7(7), pp.11-24, 2018.
- [68] Owolabi, A.B., Nsafon, B.E.K., Roh, J.W., Suh, D. and Huh, J.S., *Validating the techno-economic and environmental sustainability of solar PV technology in Nigeria using RETScreen Experts to assess its viability*, Sustainable Energy Technologies and Assessments, 36, p.100542, 2019.
- [69] Gandoman, F.H., Raeisi, F. and Ahmadi, A., *A literature review on estimating of PV-array hourly power under cloudy weather conditions*, Renewable and Sustainable Energy Reviews, 63, pp.579-592, 2016.
- [70] Gandelli, A., Grimaccia, F., Leva, S., Mussetta, M. and Ogliari, E., *Hybrid model analysis and validation for PV energy production forecasting*, In 2014 international joint conference on neural networks (IJCNN) (pp. 1957-1962). IEEE, 2014.
- [71] Bracale, A., Caramia, P., Carpinelli, G., Di Fazio, A.R. and Ferruzzi, G., *A Bayesian method for short-term probabilistic forecasting of photovoltaic generation in smart grid operation and control*, Energies, 6(2), pp.733-747, 2013.
- [72] Fonseca Junior, J.G.D.S., Oozeki, T., Ohtake, H., Takashima, T. and Ogimoto, K., *Regional forecasts of photovoltaic power generation according to different data availability*

- scenarios: a study of four methods*, Progress in Photovoltaics: Research and Applications, 23(10), pp.1203-1218, 2015.
- [73] Patarau, T., Petreus, D. and Etz, R., *Analysis and optimization of a geothermal, biomass, solar hybrid system: An application of PV Sol software*, In 2015 38th International Spring Seminar on Electronics Technology (ISSE) (pp. 370-375). IEEE, 2015.
- [74] »RPI Camera (I), Fisheye Lens,« [Mrežno]. Available: [https://www.waveshare.com/wiki/RPI_Camera_\(I\)](https://www.waveshare.com/wiki/RPI_Camera_(I)). [Pokušaj pristupa Svibanj 2023].
- [75] Sobota, J., Pišl, R., Balda, P. and Schlegel, M., *Raspberry Pi and Arduino boards in control education.*, IFAC Proceedings Volumes, 46(17), pp.7-12, 2013.
- [76] Pagnutti, M., Ryan, R.E., Cazenavette, G., Gold, M., Harlan, R., Leggett, E. and Pagnutti, J., *Laying the foundation to use Raspberry Pi 3 V2 camera module imagery for scientific and engineering purposes*, Journal of Electronic Imaging, 26(1), pp.013, 2017.
- [77] J. M. R. a. C. K. Lambert, *Power consumption profiling of a lightweight development board: Sensing with the INA219 and Teensy 4.0 microcontroller.*, Electronics, 10(7), p.775, 2021.
- [78] [Jain, M., Gollini, I., Bertolotto, M., McArdle, G., & Dev, S., *An extremely-low cost ground-based whole sky imager*, 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS (pp. 8209-8212). IEEE, 2021.
- [79] Borgman, C.L., Darch, P.T., Sands, A.E., Pasquetto, I.V., Golshan, M.S., Wallis, J.C. and Traweek, S., *Knowledge infrastructures in science: data, diversity, and digital libraries*, International Journal on Digital Libraries, 16, pp.207-227, 2015.
- [80] Drönner, J., Korfhage, N., Egli, S., Mühlhng, M., Thies, B., Bendix, J., Freisleben, B. and Seeger, B., *Fast cloud segmentation using convolutional neural networks*, Remote Sensing, 10(11), p.1782, 2018.
- [81] Radovan, A., Šunde, V., Kućak, D. and Ban, Ž., *Solar Irradiance Forecast Based on Cloud Movement Prediction*, Energies, 14(13), p.3775, 2021.

- [82] Rajagukguk, R.A., Kamil, R. and Lee, H.J., *A deep learning model to forecast solar irradiance using a sky camera*, Applied Sciences, 11(11), p.5049, 2021.
- [83] (Ahmadi, A., Han, D., Karamouz, M. and Remesan, R., *Input data selection for solar radiation estimation*, Hydrological Processes: An International Journal, 23(19), pp.2754-2764, 2009.
- [84] Šegota, T. and Filipčić, A., *Köppenova podjela klima i hrvatsko nazivlje*, Geoadria, 8(1), pp.17-37.), 2003.
- [85] »Kaggle baza podataka,« [Mrežno]. Available: <https://www.kaggle.com/datasets/alenjakoqli/sky-images-and-solar-radiation-measurement-dataset>. [Pokušaj pristupa Srpanj 2023].
- [86] Grubišić, A. and Lakos, T.R., *The island of the future: the sustainable island development model: Žirje case study*, In Book of abstracts: 2nd international scientific and professional conference" The Challenges of today (Vol. 1, p. 76), 2015.
- [87] »Current Results weather and science facts,« [Mrežno]. Available: <https://www.currentresults.com/Weather/Croatia/sunshine-annual-average.php>. [Pokušaj pristupa travanj 2019].
- [88] Frankovic, D., Kirincic, V. and Valentic, V., *A dual-axis tracking photovoltaic power plant as an educational tool*, International Journal of Electrical Engineering Education, 54(3), pp.189-207, 2017.
- [89] »Data collection server for Riteh-1 PV power plant,« [Mrežno]. Available: <https://fne-test-app.herokuapp.com/>. [Pokušaj pristupa prosinac 2019].
- [90] Hinton, G.E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.R., *Improving neural networks by preventing co-adaptation of feature detectors*, arXiv preprint arXiv:1207.0580, 2012.

- [91] Crisosto, C.; Luiz, E.W.; Seckmeyer, G., *Convolutional Neural Network for High-Resolution Cloud Motion Prediction from Hemispheric Sky Images*, *Energies* 2021, 14, 753. <https://doi.org/10.3390/en14030753>, 2021.
- [92] LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., *Gradient-based learning applied to document recognition*, *Proceedings of the IEEE*, 86(11), pp.2278-2324, 1998.
- [93] Rumelhart, David E., Geoffrey E. Hinton, and Ronald J. Williams, *Learning representations by back-propagating errors*, *Nature* 323, no. 6088 (1986): 533-536, 1986.
- [94] Hochreiter, Sepp, and Jürgen Schmidhuber, *Long short-term memory*, *Neural computation* 9, no. 8 (1997): 1735-1780, 1997.
- [95] Christopher O., »Understanding LSTM Networks,« 2015. [Mrežno]. Available: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>. [Pokušaj pristupa Lipanj 2023].
- [96] Bengio, Yoshua, Patrice Simard, and Paolo Frasconi, *Learning long-term dependencies with gradient descent is difficult*, *IEEE transactions on neural networks* 5, no. 2 (1994): 157-166, 1994.
- [97] Werbos, Paul J., *Backpropagation through time: what it does and how to do it.*, *Proceedings of the IEEE* 78, no. 10 (1990): 1550-1560, 1990.
- [98] Konstantinou, M., Peratikou, S. and Charalambides, A.G., *Solar photovoltaic forecasting of power output using lstm networks*, *Atmosphere*, 12(1), p.124, 2021.
- [99] [Mrežno]. Available: <https://generic-github-user.github.io/Image-Convolution-Playground/src/>. [Pokušaj pristupa Listopad 2022].
- [100] [Mrežno]. Available: <https://computersciencewiki.org/index.php/File:MaxpoolSample2.png>. [Pokušaj pristupa Svibanj 2023].

- [101] Baldi, P. and Sadowski, P.J., *Understanding dropout*, Advances in neural information processing systems, 26, 2013.
- [102] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R., *Dropout: a simple way to prevent neural networks from overfitting*, The journal of machine learning research, 15(1), 1929-1958, 2014.
- [103] Hecht-Nielsen, R., *Theory of the backpropagation neural network*, In Neural networks for perception (pp. 65-93). Academic Press, 1992.
- [104] Dogo, E.M., Afolabi, O.J., Nwulu, N.I., Twala, B. and Aigbavboa, C.O., *A comparative analysis of gradient descent-based optimization algorithms on convolutional neural networks*, In 2018 international conference on computational techniques, electronics and mechanical systems (CTEMS) (pp. 92-99). IEEE, 2018.
- [105] Dissawa, L.H., Godaliyadda, R.I., Ekanayake, P.B., Agalgaonkar, A.P., Robinson, D., Ekanayake, J.B. and Perera, S., *Sky image-based localized, short-term solar irradiance forecasting for multiple pv sites via cloud motion tracking*, International Journal of Photoenergy, 2021, pp.1-27, 2021.
- [106] Piacentini, Rubén D., et al., *Extreme total solar irradiance due to cloud enhancement at sea level of the NE Atlantic coast of Brazil*, Renewable Energy 36.1 (2011): 409-412, 2011.
- [107] [Mrežno]. Available: <https://www.ablebits.com/office-addins-blog/linear-regression-analysis-excel/>. [Pokušaj pristupa Lipanj 2022].
- [108] Dissawa, L., *Sky Images and PV Power Measurements for Irradiance Forecasting [Data set]*, Mendeley. <https://doi.org/10.17632/CB8T8NP9Z3.2>, 2021.
- [109] [Mrežno]. Available: <https://www.analyticsvidhya.com/blog/2021/08/image-processing-in-python-the-computer-vision-techniques/>. [Pokušaj pristupa Lipanj 2022].
- [110] [Mrežno]. Available: https://docs.opencv.org/4.5.1/d7/d4d/tutorial_py_thresholding.html. [Pokušaj pristupa Lipanj 2022].

- [111] [Mrežno]. Available: https://colab.research.google.com/drive/1_JUhm8XMT3rpE6Sv7R4KDxWTV8OC-A0n?usp=sharing. [Pokušaj pristupa Listopad 2022].
- [112] Andrianakos, G., Tsourounis, D., Oikonomou, S., Kastaniotis, D., Economou, G. and Kazantzidis, A., *Sky Image forecasting with Generative Adversarial Networks for cloud coverage prediction*, In 2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA) (pp. 1-7). IEEE, 2019.
- [113] Yang, H., Wang, L., Huang, C. and Luo, X., *3D-CNN-Based sky image feature extraction for short-term global horizontal irradiance forecasting*, *Water*, 13(13), p.1773, 2021.
- [114] Goldsborough, P., *A tour of tensorflow*, arXiv preprint arXiv:1610.01178, 2016.
- [115] Gulli, A. and Pal, S., *Deep learning with Keras*, Packt Publishing Ltd, 2017.
- [116] »CNN - LSTM model,« [Mrežno]. Available: https://colab.research.google.com/drive/1zlxpsdOF30hbwdCedJfpyia_wsN5chZm?usp=sharing. [Pokušaj pristupa Srpanj 2023].
- [117] »3D CNN model,« [Mrežno]. Available: https://colab.research.google.com/drive/1Fa89xPUq5Bwqn8EzBeoxD5aFfwgOGR_G?usp=sharing. [Pokušaj pristupa Srpanj 2023].
- [118] Pedro, H.T. and Coimbra, C.F., *Assessment of forecasting techniques for solar power production with no exogenous inputs*, *Solar Energy*, 86(7), pp.2017-2028, 2012.
- [119] Yang, C., Thatte, A.A. and Xie, L., *Multitime-scale data-driven spatio-temporal forecast of photovoltaic generation*, *IEEE Transactions on Sustainable Energy*, 6(1), pp.104-112, 2014.
- [120] Huang, C., Wang, L. and Lai, L.L., *Data-driven short-term solar irradiance forecasting based on information of neighboring sites*, *IEEE Transactions on Industrial Electronics*, 66(12), pp.9918-9927, 2018.

Popis oznaka i kratica

A	amper
f	fokus, žarišna daljina, mm
GB	gigabajt
kB	kilobajt
kW	kilovat
MB	megabajt
P	snaga
P _n	nazivna snaga
t	vrijeme
V	volt
2D	dvodimenzionalnost
3D	trodimenzionalnost
AC	izmjenična struja (eng. <i>alternative current</i>)
ANN	umjetna neuronska mreža (eng. <i>artificial neural network</i>)
CAD	(eng. <i>computer aided design</i>)
CCD	(eng. <i>charge coupled device</i>)
CMV	vektora kretanja oblaka (eng. <i>cloud motion vector</i>)
CNC	(eng. <i>computer numerical control</i>)
CNN	konvolucijska neuronska mreža (eng. <i>convolutional neural network</i>)
DC	istosmjerna struja (eng. <i>direct current</i>)
FDM	(eng. <i>fused deposition modeling</i>)
FN	fotonaponski
FNE	fotonaponska elektrana
GHI	globalna horizontalna iradijacija (eng. <i>global horizontal irradiance</i>)
GPIO	(eng. <i>general purpose input/output</i>)

GPU	grafička procesorska jedinica (eng. <i>graphics processing unit</i>)
HDMI	(eng. <i>high definition multimedia interface</i>)
IDE	integrirano razvojno okruženje (eng. <i>integrated development environment</i>)
LSTM	dugotrajno-kratkoročna memorija (eng. <i>Long Short-Term Memory</i>)
MAE	srednja apsolutna pogreška (eng. <i>mean absolute error</i>)
MSE	srednja kvadratna pogreška (eng. <i>Mean Squared Error</i>)
OIE	obnovljivi izvori energije
PET	polietilen tereftalat (eng. <i>polyethylene terephthalate</i>)
PETG	glikol modificirani polietilen tereftalat (eng. <i>polyethylene terephthalate glycol</i>)
PIL	(eng. <i>Python imaging library</i>)
PV	(eng. <i>photovoltaic</i>)
PVGIS	(eng. <i>photovoltaic geographical information system</i>)
RMSE	korijen srednje kvadratne pogreške (eng. <i>root mean squared error</i>)
RNN	rekurentna neuronska mreža (eng. <i>recurrent neural network</i>)
SBRC	istraživački centar za održive zgrade (eng. <i>sustainable buildings research centre</i>)
SGM	stohastički gradijentni spust (eng. <i>stochastic gradient descent</i>)
USB	(eng. <i>universal serial bus</i>)
UV	ultraljubičasto

Popis slika

Slika 1: Emisije stakleničkih plinova u EU po sektoru u 2021. godini [5]	2
Slika 2: Snaga fotonaponske elektrane Riteh 1	5
Slika 3: Metoda vektora kretanja oblaka	8
Slika 4: Utjecaj vremenske rezolucije dohvaćanja podataka na točnost baze podataka [40]. Usporedba podataka dobivenih s 45 sekundnim i 5 minutnim intervalom. Prikaz dva karakteristična dana; a) djelomično oblačan dan, b) oblačan dan	9
Slika 5: Klasifikacija metoda za prognoziranje proizvodnje fotonaponskih elektrana	18
Slika 6: Modul kamere	28
Slika 7: Raspberry Pi Zero računalo	29
Slika 8: Mali solarni panel	30
Slika 9: INA219 modul za mjerenje struje	31
Slika 10: 3D model modula za prikupljanje fotografija polusfere neba; a) Kućište, b) Kućište s komponentama, c) sastavljeni modul s pokrovom	32
Slika 11: Sastavljeni modul	33
Slika 12: Testni poligon za verifikaciju i evaluaciju performansi predloženog modela te usporedbu s drugim modelima	33
Slika 13: Prikupljanje informacija s intervalom uzrokovanja od 10 sekundi, jedne minute i pet minuta	37
Slika 14: Kartografski prikaz broja sunčanih sati u Europi [86]	43
Slika 15: Meteorološka postaja smještena na glavnoj zgradi Tehničkog fakulteta Sveučilišta u Rijeci	44
Slika 16: Fotonaponska elektrana Riteh 1	46
Slika 17: Proizvodnja električne energije i njena vremenska derivacija na djelomično oblačan dan	47
Slika 18: Proizvodnja električne energije i njezina vremenska derivacija za vrijeme oblačnog dana	48
Slika 19: Struktura tipične konvolucijske neuronske mreže	55
Slika 20: Artiktura LSTM mreže [95]	56

Slika 21: Distribucija podataka o proizvodnji fotonaponske energije u referentnom skupu podataka: A. distribucija PV podataka u skupu za razvoj; B. distribucija PV podataka u testnom skupu; i C. profili proizvodnje fotonaponske energije za 10 sunčanih dana i 10 oblačnih dana korištenih u testnom skupu.....	59
Slika 22: Fotografije neba i opreme za prikupljanje podataka. (A. Fotografija neba snimljena na vedar dan u 12:18:20 , 25. siječnja 2019. B. Botografija oblačnog dana snimljena u 12:32:10 , 27. svibnja 2019. C. Kamera s širokokutnim objektivom koja je korištena za snimanje neba. D. Fotonaponska elektrana čija se izlazna snaga koristi. E. Lokacije kamere i fotonaponskih panela)	60
Slika 23: Grafički prikaz izlazne snage fotonaponske elektrane Riteh 1 za dva odabrana dana ...	63
Slika 24: Predobrada nasumice odabrane fotografije: (a) Originalna fotografija; (b) smanjenje rezolucije na 64x64 piksela; (c) konverzija u crno-bijeli format	64
Slika 25: Prikaz odabranih mapa značajki generiranih konvolucijskim slojevima neuronske mreže. Svaka mapa značajki pokazuje ključne topografske značajke originalne ulazne fotografije	67
Slika 26: Konvolucija. a) ulazna fotografija, b) detektor značajki, c) mapa značajki [99].....	67
Slika 27: Princip rada sloja maksimalnog grupiranja [100].....	68
Slika 28: Poravnavanje.....	69
Slika 29: Gašenja pojedinih neurona neuronske mreže. a) standardna neuronska mreža s 2 skrivena sloja. b) primjer razrijeđene mreže [102]	71
Slika 30: Predikcija budućih fotografija.....	75
Slika 31: Ulazni podaci: Snaga na dan 10. rujna 2019.....	76
Slika 32: Dio fotografija koje su sadržane u bazi podataka	77
Slika 33: Distribucija ulaznih podataka	78
Slika 34: Detekcija oblaka metodom graničnih vrijednosti. (a) izvorna fotografija (b) obrađena fotografija	81
Slika 35: Postupak dodavanja maske na sliku. (a) Izvorna fotografija (b) maska (c) fotografija nakon obrade	82
Slika 36: Metoda graničnih vrijednosti. (a) izvorna fotografija (b) <i>Simple Thresholding</i> (c) <i>Adaptive thresholding</i> [110].....	83
Slika 37: Sumarni prikaz modela	85

Slika 38: Usporedba stvarne i predviđene snage uporabom metode Svjetlina plave boje na cijelim fotografijama	88
Slika 39: Usporedba stvarne i predviđene snage uporabom Metode graničnih vrijednosti na cijelim fotografijama	88
Slika 40: Usporedba stvarne i predviđene snage uporabom višestruke linearne regresije s 9 nezavisnih varijabli	90
Slika 41: Funkcija gubitaka treninga.....	94
Slika 42: Rezultati modela konvolucijske neuronske mreže.....	95
Slika 43: Prikaz predviđanja snage za nasumice odabranu fotografiju.....	95
Slika 44: Usporedba stvarne snage s predviđenom snagom	96
Slika 45: Struktura razvijenog hibridnog modela	100
Slika 46: Sažetak arhitekture hibridnog CNN-LSTM modela, prikazujući niz slojeva, njihove izlazne oblike i broj parametara koje je moguće trenirati	103
Slika 47: Struktura razvijenog 3D CNN modela.....	104
Slika 48: Podaci korišteni za analitičku procjenu modela.....	107
Slika 49: Usporedna analiza stvarnih i predviđenih snaga fotonaponske elektrane za odabrane sunčane i pretežno oblačne dane	110
Slika 50: Dijagram raspršenosti. Prikaz stvarne snage u odnosu na predviđenu izlaznu snagu fotonaponske elektrane.....	111
Slika 51: Usporedna analiza stvarnih i predviđenih snaga fino podešenim hibridnim CNN-LSTM modelom.....	112
Slika 52: Dijagram raspršenosti. Prikaz stvarne snage u odnosu na predviđenu izlaznu snagu dobivenu fino podešenim hibridnim CNN-LSTM modelom.....	112
Slika 53: Usporedba baznog modela i fino podešenog hibridnog CNN-LSTM modela	113
Slika 54: Usporedba stvarne izlazne snage FNE Riteh 1 i snage predviđene hibridnim CNN-LSTM modelom.....	114
Slika 55: Dijagram raspršenosti: Prikaz stvarne snage FNE Riteh 1 u odnosu na predviđenu snagu; a) vedar dan, b) pretežno oblačan dan, c) ukupni testni skup	115
Slika 56: Dijagram raspršenosti: Prikaz stvarne snage u odnosu na predviđenu izlaznu snagu fotonaponske elektrane uporabom 3D CNN modela	116
Slika 57: Usporedba 3D CNN i hibridnog CNN-LSTM modela	117

Slika 58: Utjecaj duljine ulaznih podataka na točnost predviđanja	119
Slika 59: Utjecaj duljine ulaznih podataka na predviđanje: nemogućnost predviđanja za prva dva sata proizvodnje kod uporabe modela s duljinom ulazne sekvence fotografija od dva sata	120
Slika 60: Performanse modela pri različitim vremenskim rezolucijama ulaznih podataka	121
Slika 61: Usporedba stvarne i predviđene proizvodnje fotonaponskih elektrana tijekom pretežito oblačnih dana; a) rezolucija ulaznih podataka: 5 min; b) rezolucija ulaznih podataka: 15 min ..	122
Slika 62: Analiza modela s različitim horizontima predviđanja	123

Popis tablica

Tablica 1: Sumarni prikaz klasifikacije prognoze proizvodnje fotonaponskih elektrana na temelju horizonta predviđanja	22
Tablica 2: Popis komponenti modula za kratkoročnu prognozu proizvodnje FNE	34
Tablica 3: Meteorološki podaci za odabrane gradove u Republici Hrvatskoj	44
Tablica 4: Granične vrijednosti koje se koriste u izračunima	49
Tablica 5: Broj prijelaznih pojava u skupinama A i B	49
Tablica 6: Promjene u proizvodnji fotonaponskih elektrana	50
Tablica 7: Rezultati regresijske analize	87
Tablica 8: Višestruka linearna regresija	89
Tablica 9: Rezultati višestruke linearne regresije s devet nezavisnih varijabli	90
Tablica 10: Rezultati višestruke linearne regresije s četiri nezavisne varijable	91
Tablica 11: Rezultati višestruke linearne regresije s tri nezavisne varijable	91
Tablica 12: Rezultati višestruke linearne regresije s dvije nezavisne varijable	91
Tablica 13: Rezultati testiranja prognoziranja stvarne izlazne snage FNE Riteh 1	115

PODACI O AUTORU

Alen Jakoplić rođen je 23. srpnja 1991. u Zagrebu. Nakon završene Tehničke škole Kutina kao procesni tehničar 2010. godine, upisuje Tehničko veleučilište u Zagrebu gdje 2015. godine stječe zvanje stručnog prvostupnika inženjera elektrotehnike. Obrazovanje nastavlja na Tehničkom fakultetu Sveučilišta u Rijeci gdje 2017. godine pod mentorstvom prof. dr. sc. Dubravka Frankovića brani magistarski rad "Primjena baterija kao skladišta energije unutar EES-a" te stječe titulu magistra inženjera elektrotehnike.

Od lipnja 2017. godine, kratak period radio je kao profesor u Poštanskoj i telekomunikacijskoj školi u Zagrebu, a u prosincu iste godine zapošljava se na Tehničkom fakultetu u Rijeci kao asistent na Zavodu za elektroenergetiku. Uz znanstveno-istraživački rad, sudjeluje i u izvođenju nastave: pri Diplomskom sveučilišnom studiju sudjeluje na kolegijima: "Elektrane", "Projektiranje električnih postrojenja" i "Vođenje elektroenergetskog sustava"; u izvođenju kolegija preddiplomskog studija "Osnove elektrotehnike I" i "Električna postrojenja", te na kolegiju "Osnove projektiranja elektroenergetskih postrojenja" u sklopu Stručnog studija.

Poslijediplomski doktorski studij pod mentorstvom prof. dr. sc. Dubravka Frankovića upisuje 2018. godine. Kroz svoj znanstveni rad i doktorski studij sudjeluje na četiri znanstvene konferencije te postaje autor dva objavljena znanstvena članka. Svoju profesionalnu karijeru nastavlja graditi u Rijeci gdje živi i radi. Materinski jezik mu je hrvatski, a u govoru i pismu aktivno se služi i engleskim jezikom.

POPIS OBJAVLJENIH RADOVA AUTORA

Izvorni znanstveni članci:

1. Jakoplić, A., Franković, D., Kirinčić, V. and Plavšić, T., 2021. Benefits of short-term photovoltaic power production forecasting to the power system. *Optimization and Engineering*, 22, pp.9-27.
2. Jakoplić, A., Franković, D., Havelka, J. and Bulat, H., 2023. Short-Term Photovoltaic Power Plant Output Forecasting Using Sky Images and Deep Learning. *Energies*, 16(14), p.5428.

Konferencije:

1. Jakoplić, Alen; Vlahinić, Saša; Dobraš, Branka; Franković, Dubravko Sky Image Analysis and Solar Power Forecasting: A Convolutional Neural Network Approach. // *Renewable Energy and Power Quality Journal (RE&PQJ)*// Lalin Pontevedra (Spain): 2023. str.1 - 6.
2. Jakoplić, A., Franković, D., Kirinčić, V. and Sterpin, I., 2017. short-term solar forecasting based on sky images to enable PV integration.
3. Jakoplic, A., Frankovic, D., Kirincic, V. and Havelka, J., 2018, November. Short-term photovoltaic power forecasting using cloud tracking methods. In *Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion (MEDPOWER 2018)* (pp. 1-5). IET.
4. Franković, D., Bulić, N., Jakoplić, A. and Rosanda, B., 2019. Reefer container power supply and supervision system onboard railway wagons. *Innovations*, 7(2), pp.73-76.
5. Kirinčić, Vedran ; Franković, Dubravko ; Radulović, Duško ; Jakoplić, Alen Towards a low-carbon island society by strong implementation of electromobility. // *Proceedings of International Conference on Innovative Technologies 2018*// Car, Zlatan ; Kudlaček, Jan (ur.) Zagreb 2018. str.169 - 172.
6. Franković, Dubravko ; Rosanda, Boris ; Jakoplić, Alen ; Kirinčić, Vedran
7. Power supply system for railway applications// *Proceedings of International Conference on Innovative Technologies 2018/ Car, Zlatan ; Kudlaček, Jan (ur.)*. Zagreb, 2018. str. 161-164 .