

**SVEUČILIŠTE U SPLITU
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I
BRODOGRADNJE**

DOKTORSKI STUDIJ STROJARSTVA

KVALIFIKACIJSKI DOKTORSKI ISPIT

**PRIMJENA METODA STROJNOG UČENJA
U VODIKOVIM TEHNOLOGIJAMA**

Nikola Franić

Split, lipanj 2024.

SADRŽAJ

1. UVOD.....	1
2. PREGLED NAJČEŠĆE KORIŠTENIH METODA STROJNOG UČENJA U VODIKOVIM TEHNOLOGIJAMA	5
2.1. Evaluacijske metrike metoda strojnog učenja.....	7
3. PRIMJENA STROJNOG UČENJA U PREDVIĐANJU RADNIH PARAMETARA VODIKOVIH TEHNOLOGIJA.....	8
4. PRIMJENA STROJNOG UČENJA U DEGRADACIJI, DIJAGNOSTICI I PROGNOTICI VODIKOVIH TEHNOLOGIJA.....	18
5. PRIMJENA STROJNOG UČENJA U OTKRIVANJU KVAROVA VODIKOVIH TEHNOLOGIJA.....	24
6. RASPRAVA I KRITIČKI OSVRT NA DOSADAŠNJA ISTRAŽIVANJA	29
6.1. Usporedba i sposobnosti ML metoda.....	29
6.2. Izazovi u vezi s podacima i generalizacijom.....	30
6.3. Digitalni blizanci kao budućnost primjene ML metoda.....	30
7. ZAKLJUČAK	32
LITERATURA	33
POPIS OZNAKA I KRATICA	38
SAŽETAK.....	40
ABSTRACT.....	41

1. UVOD

Vodikove tehnologije u sprezi s obnovljivim izvorima energije, svojim ekološkim karakteristikama i učinkovitoj pretvorbi energije u usporedbi s neobnovljivim izvorima energije poput ugljena i prirodnog plina, pozicionirale su se kao jedno od ključnih rješenja za održivu energetska budućnost [1]. Iscrpljivanje fosilnih goriva, te onečišćenje i degradacija okoliša zbog efekta staklenika potaknuli su mnoge zemlje na prelazak na obnovljive izvore energije. U ovom tranzicijskom procesu vodik ima ključnu ulogu, što se ogleda i u planovima Europske unije koja planira do 2030. godine proizvesti 10 milijuna tona vodika [2]. Primjena vodika može se pronaći u motorima s unutarnjim izgaranjem (engl. *Internal Combustion Engine*, ICE) i u gorivnim člancima za proizvodnju električne energije. Njegova energetska učinkovitost najveća je u primjeni kod gorivnih članaka, što je ujedno ključni faktor za njihovu komercijalizaciju [3]. S druge strane, vodik se može proizvesti kao produkt mnogih procesa kao što su termokemijski [4], elektrokemijski [5], biološki [6], i fotokatalitički procesi [7]. Dva glavna procesa proizvodnje vodika su parna reformacija prirodnog plina, te elektroliza vode koja može biti pokretana električnom energijom iz fosilnih i nuklearnih goriva, te obnovljivih izvora energije [8].

Korištenjem isključivo obnovljivih izvora energije za proizvodnju električne energije potrebne za elektrolizu dobiva se tzv. zeleni vodik [9], i to najčešće korištenjem tzv. membranskih elektrolizatora (engl. *Proton Exchange Membrane Water Electrolyzer*, PEMWE), ali i alkalijskih elektrolizatora (engl. *Alkaline Electrolyzer*, AE), te još uvijek nedovoljno razvijenih elektrolizatora s krutim oksidom (engl. *Solid Oxide Electrolyzer*, SOE) ili kombiniranih alkalno-membranskih elektrolizatora (engl. *Anion Exchange Membrane*, AEM), kao i potencijalno zanimljivih pokušaja poput tzv. mikrobnih elektrolizatorskih članaka (engl. *Microbial Electrolysis Cell*, MEC). Trenutno se PEMWE ipak nameće kao najperspektivnije rješenje jer ga karakterizira visoka gustoća struje, niska propusnost plina kroz membranu, visoka čistoća proizvedenog vodika, modularnost koja omogućuje veliki raspon raspoloživih snaga i relativno brzi odziv na promjene potražnje što doprinosi njihovoj produktivnosti [10], stabilnosti [11] i ekonomskoj održivosti [12].

Na području korištenja vodika za proizvodnju električne energije, postoji nekoliko tehnologija gorivnih članaka koje se razlikuju prema korištenom elektrolitu pa se mogu podijeliti na tzv. membranske gorivne članke (engl. *Proton Exchange Membrane Fuel Cell*, PEMFC), gorivne članke s krutim oksidom (engl. *Solid Oxide Fuel Cell*, SOFC), alkalijske gorivne članke (engl. *Alkaline Fuel Cell*, AFC), gorivne članke s fosfornom kiselinom (engl. *Phosphoric Acid Fuel Cell*, PAFC) i gorivne članke s rastopljenim karbonatom (engl. *Molten Carbonate Fuel Cell*, MCFC), uz potencijalno zanimljive pokušaje poput tzv. mikrobnih gorivnih članaka (engl. *Microbial Fuel Cell*, MFC). Sve vrste gorivnih članaka, a ponajviše PEMFC zbog rada na nižim temperaturama (60–80 °C) i modularnosti, mogu se naći u različitim primjenama, od malih prijenosnih uređaja za proizvodnju električne energije do velikih stacionarnih uređaja za proizvodnju električne energije, te u različitim vrstama vozila [13], pružajući čišću alternativu ICE-ima [14].

Ipak, unatoč značajnom napretku vodikovih tehnologija posljednjih godina, ostaje nekoliko izazova koji sprječavaju njihovu širu primjenu, a jedna od glavnih tehničkih prepreka je isplativija proizvodnja vodika. Elektroliza, posebno korištenjem PEMWE-a, iako obećavajuća, još uvijek je skup proces zbog oslanjanja na rijetke i skupe plemenite metale, poput platine, iridija i rutenija, kao katalizatore [15], pa tako povećavaju inicijalnu cijenu elektrolizatora i čine ovu tehnologiju

manje konkurentnom. Osim toga, u području gorivnih članaka, održavanje dugoročnih performansi bez značajne degradacije predstavlja i dalje veliki izazov. Izdržljivost i stabilnost ovih sustava pod dugotrajnim radnim uvjetima još uvijek ne zadovoljava industrijske standarde potrebne za široku primjenu [16]. Također, neodgovarajuće početno kondicioniranje ili aktiviranje membrana može prouzrokovati nepouzdana rezultate i zaključke, stoga je ključno definirati i provesti odgovarajuće postupke aktivacije prije provođenja ispitivanja degradacije kako bi se osigurala točne usporedbe i zaključci [17]. Materijali i komponente korišteni u većini gorivnih članaka moraju izdržati vrlo zahtjevna radna okruženja i korozivne uvjete. U primjeru PEMFC-a, degradacija membrane temeljem različitih mehanizama trošenja značajno utječe na učinkovitost i životni vijek gorivnog članka [18]. S druge strane, u primjeru SOFC-a rad na visokim temperaturama zahtijeva upotrebu posebnih i vrlo skupih materijala. Međutim, nedavna istraživanja pokazuju potencijal i za korištenje jeftinijih materijala poput nehrđajućeg čelika [19], te smanjenje radne temperature smanjenjem debljine elektrolita ili uvođenjem drugog elektrolita s visokom ionskom provodljivošću kisika [20].

Ekonomska održivost vodikovih tehnologija predstavlja trenutno možda i najveći izazov. Visoki početni kapitalni troškovi povezani sa zahtjevnom proizvodnjom, skladištenjem i distribucijskom infrastrukturom za vodik usporavaju širu primjenu ovih tehnologija jer još uvijek nisu postali cjenovno konkurentni postojećim energetske tehnologijama [21]. Cijenu vodika, posebno zelenog vodika proizvedenog elektrolizom uz korištenje obnovljive energije, potrebno je još značajno smanjiti kako bi postao isplativa alternativa za masovnu potrošnju [22]. U usporedbi s fosilnim gorivima, zeleni vodik ima brojne prednosti poput visoke ogrjevne vrijednosti i bez štetnih utjecaja na okoliš, ali i nedostatke kao što su lako curenje, niska minimalna energija potrebna za zapaljenje, relativno široko područje zapaljivosti u zraku, te utjecaj na povećanje krtosti metalnih spremnika što predstavlja značajne tehničke izazove pri njegovom skladištenju i transportu [23], ali i sigurnosne izazove ukoliko se s njim ne rukuje na ispravan način [24]. Trenutno skladištenje vodika je moguće u sva tri agregacijska stanja, uz različita ograničenja u pogledu energetske gustoće, troškova i sigurnosti [25], ali i dalje prednjače visokotlačni spremnici.


Razvoj sveobuhvatne vodikove infrastrukture, uključujući proizvodne pogone, punionice i transportne mreže [26], također predstavlja prepreku širokoj primjeni vodikovih tehnologija jer se do sada nije odvijao dovoljno brzo i paralelno s razvojem tehnologije. Međutim, trošak razvoja potpuno nove infrastrukture je iznimno visok, ali bi se mogao smanjiti prenamjenom postojeće plinske infrastrukture [27]. Neke procjene sugeriraju da bi prenamjena postojeće plinske infrastrukture mogla koštati 10-15% cijene potpuno nove infrastrukture [28]. S druge strane, regulatorni okviri i sigurnosni standardi za proizvodnju, skladištenje i upotrebu vodika zahtijevaju daljnji razvoj i harmonizaciju među različitim regijama i sektorima kako bi se izbjegle pravne nesigurnosti [29], jer to je ono što trenutno najviše otežava ulaganja i usporava odobrenja novih projekata u daljnjem razvoju vodikove infrastrukture. S druge strane, osiguravanje sigurnog rukovanja vodikom, posebno u javnim i stambenim područjima, ključno je za stjecanje povjerenja javnosti i olakšavanje integracije vodikovih tehnologija u energetske sustav [30].

Stoga, iako tehnologije vodika imaju ogroman potencijal za održivu energetske budućnost, rješavanje ovih izazova je nužno za njihovu uspješnu integraciju u postojeću globalnu energetske mrežu. Inovacije u materijalima, inženjerstvu i dizajnu sustava, uz podržavajuće politike i ulaganja, bit će presudne za prevladavanje ovih prepreka i otključavanje punog potencijala vodika kao ključnog energenta u postupnom prijelazu na obnovljive izvore energije, a jedan od alata koji


bi svakako trebao u tome pomoći je i primjena umjetne inteligencije, posebno primjena metoda strojnog učenja (engl. *Machine Learning*, ML).

Uloga strojnog učenja u napredovanju vodikovih tehnologija postaje sve značajnija, nudeći nova rješenja za različite izazove u ovom području. ML sa svojom sposobnošću obrade velikih skupova podataka i otkrivanja složenih obrazaca, pokazalo se kao koristan alat za optimizaciju performansi, pouzdanosti i isplativosti vodikovih sustava [31]. U području proizvodnje vodika, posebice elektrolize, ML algoritmi mogu optimizirati radne parametre kako bi povećali učinkovitost i smanjili troškove. Analizom podataka iz različitih izvora, ML modeli mogu predvidjeti optimalne uvjete za elektrolizu, minimizirajući potrošnju energije i maksimizirajući proizvodnju vodika [32]. Ovi modeli također mogu pomoći u razvoju učinkovitijih i jeftinijih katalizatora predviđanjem svojstava materijala i njihovih interakcija s elektrolitičkim okruženjem [33]. ML tehnike mogu se primijeniti za poboljšanje dizajna i rada gorivnih članaka, posebno PEMFC-ova i SOFC-ova. Analizom radnih podataka, ML modeli mogu predvidjeti performanse pod različitim uvjetima, omogućujući postizanje optimalne ravnoteže između učinkovitosti i dugotrajnosti [34]. Nadalje, ML može olakšati razvoj novih materijala za membrane i elektrode, predviđajući njihove performanse i trajnost, što može dovesti do značajnih napredaka u tehnologiji gorivnih članaka [35]. Jedna od najvrjednijih primjena ML-a u vodikovim tehnologijama je predviđanje degradacije i procjena životnog vijeka sustava. Analizom povijesnih podataka i praćenjem u stvarnom vremenu, ML algoritmi mogu identificirati rane znakove trošenja ili potencijalnih kvarova komponenti, omogućujući prediktivno održavanje i značajno smanjivanje vremena zastoja i troškova popravaka [36]. Ova prediktivna sposobnost ključna je za postizanje pouzdanosti i održivosti vodikovih sustava, posebno u kritičnim primjenama poput transporta i stacionarne proizvodnje energije. ML također ima vitalnu ulogu u integraciji proizvodnje vodika s obnovljivim izvorima energije. Može predvidjeti dostupnost vjetrove ili solarne energije, optimizirajući vrijeme i opseg proizvodnje vodika kako bi se uskladila opskrba energijom s potražnjom korisnika. Ova integracija pomaže u stvaranju fleksibilnijeg i učinkovitijeg energetskeg sustava, gdje vodik djeluje kao medij za skladištenje viškova obnovljive energije, čime se povećava ukupna otpornost energetskih mreža [37]. S infrastrukture strane, ML može optimizirati lanac opskrbe vodikom, od proizvodnje i skladištenja do distribucije i punjenja. Analizom logističkih podataka, ML modeli mogu identificirati najučinkovitije rute i metode za transport vodika, smanjujući troškove i poboljšavajući pouzdanost lanca opskrbe [38].

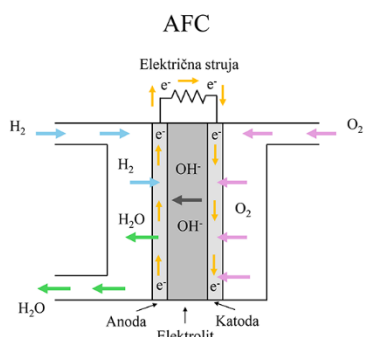
Dakle, primjena ML-a u vodikovim tehnologijama pruža inovativna rješenja koja povećavaju učinkovitost, smanjuju troškove, te poboljšavaju pouzdanost i održivost vodikovih sustava. Stoga, daljnjim razvojem industrije vodika, integracija ML-a bit će ključna u rješavanju tehničkih i ekonomskih izazova, otvarajući put ka čistoj i održivoj energetskoj budućnosti. Međutim, kako bi se moglo pronaći prostor za daljnje nadogradnje ovoga područja, u narednim poglavljima bit će predstavljen trenutni pregled najčešće korištenih ML metoda u literaturi, te sveobuhvatni pregled i kritički osvrt na trenutna istraživanja o predviđanju, degradaciji i otkrivanju kvarova na razini uređaja različitih vodikovih tehnologija. Dosadašnja istraživanja primjene metoda strojnog učenja s različitim ciljevima, analizirana detaljno u nastavku ovog preglednog rada, rađena su na nekolicini ranije spomenutih vodikovih tehnologija, a njihove ilustracije, uz kratke opise principa rada, prikazane su na slici 1.1.




PEMFC pretvara kemijsku energiju iz vodika i kisika u električnu energiju, s vodom i toplinom kao nusproduktima




SOFC pretvara kemijsku energiju iz goriva poput vodika ili ugljikovodika i kisika u električnu energiju, s vodom, ugljikovim dioksidom (ako se koriste ugljikovodici) i toplinom kao nusproduktima




AFC pretvara kemijsku energiju iz vodika i kisika u električnu energiju, proizvodeći vodu i toplinu kao glavne nusprodukte




PAFC pretvara kemijsku energiju iz vodika i kisika u električnu energiju, s vodom, toplinom i fosfornom kiselinom kao nusproduktima




MCFC pretvara kemijsku energiju iz prirodnog plina i kisika u električnu energiju, s vodom, ugljikovim dioksidom i toplinom kao primarnim nusproduktima



MFC pretvara kemijsku energiju iz organske tvari u električnu energiju, s vodom, ugljikovim dioksidom i biomasom kao nusproduktima



PEMWE pretvara električnu energiju u kemijsku energiju razdvajanjem vode na vodik i kisik, s vodom kao primarnom sirovinom i vodikom i kisikom kao nusproduktima



MEC pretvara kemijsku energiju iz organske tvari u vodikov plin kroz mikrobn metabolizam i električnu energiju, proizvodeći vodik i organske nusprodukte

Slika 1.1. Ilustracije i kratki opisi principa rada vodikovih uređaja na kojima su do sada primijenjene metode strojnog učenja u literaturi, a koja je detaljno analizirana u ovom preglednom radu

2. PREGLED NAJČEŠĆE KORIŠTENIH METODA STROJNOG UČENJA U VODIKOVIM TEHNOLOGIJAMA

ML metode su integralne za širok spektar primjena u različitim industrijama, od financija i zdravstva do marketinga i autonomnih vozila. Učenje pod nadzorom (engl. *supervised learning*), temelj mnogih zadataka ML-a, omogućuje algoritmima da nauče odnose između ulaznih i izlaznih podataka treniranjem na označenim skupovima podataka. Ovaj pristup je naročito učinkovit za probleme klasifikacije, gdje algoritam mora kategorizirati ulazne podatke u unaprijed definirane kategorije, i probleme regresije, koji uključuju predviđanje kontinuiranih ishoda. Unutar učenja pod nadzorom, algoritmi poput *Support Vector Machines* (SVM), *Random Forests* (RF) i *Deep Neural Networks* (DNN) omogućuju rješavanje složenih problema s višedimenzionalnim podacima. S druge strane, učenje bez nadzora (engl. *unsupervised learning*) omogućuje algoritmima da otkriju skrivene strukture ili obrasce unutar neoznačenih podataka, olakšavajući zadatke poput grupiranja, redukcije dimenzionalnosti i otkrivanja anomalija. Tehnike poput *k-means clustering*, *principal component analysis* i *autoencoders* omogućuju otkrivanje temeljne strukture u podacima bez eksplicitnih smjernica. Međutim, podržano učenje (engl. *reinforcement learning*) pristupa problemu na drugačiji način, fokusirajući se na treniranje agenata da donose sekvencijalne odluke u dinamičnim okruženjima. Ovaj pristup, inspiriran psihologijom ljudskog ponašanja, koristi signale nagrade kako bi potaknuo poželjne radnje i kaznio nepoželjne, omogućujući agentima da nauče optimalne strategije kroz pokušaje i pogreške. Podržano učenje pronalazi primjenu u raznim područjima, uključujući robotiku, igre i financijsko trgovanje. Noviji pristupi kao što su polu-nadzirano (engl. *semi-supervised learning*) i samo-nadzirano učenje (engl. *self-supervised learning*) premošćuju jaz između nadziranih i nenadziranih tehnika, iskorištavajući i označene i neoznačene podatke za poboljšanje performansi modela. Ilustracija kategorija ML metoda i uobičajenih zadataka na kojima se primjenjuju prikazana je na slici 2.1.



Slika 2.1. Podjela metoda strojnog učenja na temelju zadataka na koje se primjenjuju

Linearna regresija (engl. *linear regression*) je jedan od najjednostavnijih, ali moćnih algoritama učenja pod nadzorom koji se koristi za zadatke regresije. Cilj joj je modelirati odnos između zavisne varijable i jedne ili više nezavisnih varijabli prilagođavanjem linearne jednadžbe promatranim podacima. Linearna regresija nastoji procijeniti vrijednosti tih koeficijenata tako da linija najbolje odgovara podacima, minimizirajući razliku između stvarnih i predviđenih vrijednosti, tzv. ostatak ili rezidual. Ovo se obično postiže minimiziranjem zbroja kvadrata reziduala ili optimizacijom drugih ciljeva kao što je srednja kvadratna pogreška. Linearna regresija je računalno učinkovita i interpretabilna, što je čini pogodnom za scenarije gdje je odnos između varijabli približno linearan. Međutim, ona pretpostavlja linearni odnos između varijabli, što možda nije uvijek slučaj. Za rješavanje nelinearnih odnosa, mogu se primijeniti tehnike poput polinomijalne regresije ili transformacije podataka. Linearna regresija je i osjetljiva na iznimke i multikolinearnost, što može utjecati na točnost predviđanja modela. Međutim, unatoč ovim ograničenjima, linearna regresija ostaje temeljni alat podatkovnih znanstvenika, pružajući vrijedne uvide u odnose između varijabli i služeći kao osnovna metoda za složenije tehnike modeliranja.

Stabla odluke (engl. *decision trees*) su svestrani algoritmi učenja pod nadzorom koji se koriste za probleme klasifikacije i regresije. Stablo odluke rekurzivno dijeli podatkovni prostor u regije, pri čemu je svaki dio definiran odlukom na temelju jednog podatka. Na svakom čvoru stabla, algoritam odabire podatak koji najbolje dijeli podatke na temelju odabranog kriterija, kao što je *Gini impurity* ili srednja kvadratna pogreška za regresiju. Ovaj se proces nastavlja dok se ne ispuni kriterij zaustavljanja, npr. dostizanje maksimalne dubine stabla ili minimalnog broja instanci u čvoru. Stabla odluke su jednostavna za interpretaciju i vizualizaciju, što ih čini korisnima za razumijevanje procesa donošenja odluka modela. Međutim, sklona su pretjeranom prilagođavanju, posebno kada su stabla duboka ili kada je skup podataka šumovit. Za rješavanje ovog problema često se koriste metode ansambla (engl. *ensemble*), kao što su RF i *gradient boosting machines*, koje kombiniraju više stabala odluka kako bi se poboljšale performanse generalizacije.

Support Vector Machines (SVM) je moćan algoritam nadziranog učenja koji se primarno koristi za zadatke klasifikacije, ali se može prilagoditi i za regresiju *Support Vector Regression* (SVR). U klasifikaciji, cilj SVM-a je pronaći hiperplohu koja najbolje razdvaja kategorije u podatkovni prostor, maksimizirajući marginu, što je udaljenost između hiperplohe i najbližih točaka podataka iz svake kategorije, poznatih kao potporni vektori. Ova hiperploha se odabire tako da maksimizira marginu, čineći granicu odluke otpornom na šum i dobro generalizirajući na neviđene podatke. SVM može, također, obrađivati nelinearno razdvojive podatke, mapirajući izvorni podatkovni prostor u prostor više dimenzije gdje kategorije postaju linearno razdvojive. S druge strane, SVR, umjesto pronalaženja hiperplohe, nastoji prilagoditi što više instanci unutar specificirane margine tolerancije, što ga čini pogodnim za regresijske zadatke.

Neuronske mreže (engl. *Neural Networks*, NN), osobito *Deep Neural Networks* (DNN), predstavljaju skup izrazito fleksibilnih i moćnih ML modela koji su stekli veliku popularnost posljednjih godina. Inspirirane strukturom i funkcijom bioloških neurona u ljudskom mozgu, NN sastoje se od međusobno povezanih slojeva umjetnih neurona ili čvorova, organiziranih u ulazni sloj, jedan ili više skrivenih slojeva te izlazni sloj. Svaki neuron primjenjuje transformaciju na ulazne podatke koristeći skup parametara koji se mogu naučiti, poznatih kao težine i pristranosti, te prosljeđuje rezultat kroz aktivacijsku funkciju kako bi u model unio nelinearnost. Tijekom procesa treniranja, ove težine i pristranosti se iterativno prilagođavaju koristeći optimizacijske algoritme, kao što je gradijentni spust, kako bi se minimizirala odabrana funkcija gubitka koja mjeri razliku između predviđanja modela i stvarnih ciljeva.

U zadacima klasifikacije, NN uče mapirati ulazne podatke na vjerojatnosti kategorije, dok u zadacima regresije predviđaju kontinuirane ciljne vrijednosti. Dubina i širina mreže, kao i izbor aktivacijskih funkcija i tehnika regularizacije, ključni su čimbenici koji utječu na sposobnost modela da uči složene obrasce iz podataka. Arhitekture dubokog učenja (engl. *Deep Learning*, DL), koje obično sadrže NN s mnogo skrivenih slojeva, postigle su izvanredan uspjeh u raznim domenama, uključujući prepoznavanje slika i govora, obradu prirodnog jezika i podržano učenje.

Konvolucijske neuronske mreže (engl. *Convolutional Neural Networks*, CNN) izvrsne su u analizi prostornih podataka kao što su slike, dok su rekurentne neuronske mreže (engl. *recurrent neural networks*) prikladne za sekvencijalne podatke. Unatoč njihovim impresivnim performansama, NN se često kritiziraju zbog svoje *black-box* prirode, što otežava interpretaciju kako dolaze do svojih predviđanja. Također, treniranje DNN zahtijeva velike količine podataka i računalnih resursa, što često može biti ograničavajući faktor za njihovu primjenu.

Ipak, kontinuirana istraživanja u arhitekturama NN, optimizacijskim algoritmima i tehnikama regularizacije nastavljaju pomicati granice onoga što je moguće s ovim svestranim skupom modela, potičući tako napredak u umjetnoj inteligenciji i ML-u.

2.1. Evaluacijske metrike metoda strojnog učenja

Evaluacijske metrike pružaju kvantitativne mjere o tome koliko dobro model generalizira na neviđenim podacima i koliko učinkovito ostvaruje svoj predviđeni zadatak. Jedna od često korištenih metrika za zadatke klasifikacije je točnost, koja mjeri udio ispravno klasificiranih instanci od ukupnog broja instanci. Iako točnost pruža jednostavnu mjeru ukupnih performansi, ona nije prikladna za neuravnotežene skupove podataka gdje jedna kategorija dominira nad drugima. U takvim slučajevima, metrike poput preciznosti, odziva i F1 rezultata nude bolji uvid u performanse modela. Preciznost mjeri udio točnih pozitivnih predviđanja među svim pozitivnim predviđanjima, naglašavajući sposobnost modela da izbjegne lažno pozitivne rezultate. Odziv, također poznat kao osjetljivost, kvantificira udio točnih pozitivnih predviđanja među svim stvarnim pozitivnim slučajevima, pokazujući sposobnost modela da uhvati relevantne instance. F1 rezultat kombinira preciznost i odziv u jednu metriku, pružajući uravnoteženu mjeru performansi modela. Za zadatke regresije, metrike kao što su srednja kvadratna pogreška (engl. *Mean Squared Error*, MSE) i srednja apsolutna pogreška (engl. *Mean Absolute Error*, MAE) kvantificiraju razliku između predviđenih i stvarnih vrijednosti, pri čemu niže vrijednosti ukazuju na bolje performanse. Dodatno, metrike poput R-kvadrata (engl. *R-squared*), znanog i kao koeficijent determinacije, pružaju uvid u udio varijance u ciljnoj varijabli objašnjenom modelom.

Osim ovih temeljnih metrika, specifični kriteriji evaluacije mogu biti potrebni za specijalizirane zadatke, kao što je područje ispod krivulje primateljeve radne karakteristike za binarnu klasifikaciju s neuravnoteženim podacima ili srednja prosječna preciznost za zadatke detekcije objekata u računalnom vidu. Štoviše, u podržanom učenju, evaluacijske metrike često uključuju mjere performansi agenta kao što su kumulativna nagrada, prosječna nagrada po epizodi ili stopa uspjeha u izvršavanju zadataka. Pažljivim odabirom i interpretacijom metrika evaluacije, prilagođenih specifičnim zadacima i domenama, mogu se identificirati područja za poboljšanje, točno procijeniti performanse modela, te na kraju potaknuti napredak u ML-u.

3. PRIMJENA STROJNOG UČENJA U PREDVIĐANJU RADNIH PARAMETARA VODIKOVIH TEHNOLOGIJA

Ovo poglavlje pruža uvid u trenutna istraživanja koja primjenjuju ML metode u predviđanju performansi vodikovih tehnologija na razini uređaja. Analizirana su različita istraživanja u kojima su ML tehnike korištene za predviđanje ključnih parametara i odziva sustava, od napona i temperature do polarizacijskih i impedancijskih krivulja.

Jedan od prvih primjera primjene ML metoda u vodikovim tehnologijama bila su istraživanja u kojima su izlazni napon i temperatura katode PEMFC-a Nuvera 5 kW predviđani korištenjem metode sklopa NN od strane Napolija i sur. [39] i standardne NN od strane Chávez-Ramíreza i sur. [40]. U istraživanju Napolija i sur. [39], autori su generirali skup podataka za treniranje NN promjenom parametara struje, protoka vodika, protoka dušika i protoka zraka, koji su zatim korišteni kao ulazni podaci, a temperatura katode i napon sustava korišteni su kao izlazni podaci. Nasumično odabranih 150 primjera izabrano je za treniranje modela, a 300 različitih primjera za testiranje. Testirane su NN s jednim skrivenim slojem i različitim brojem neurona, a najbolji model kombiniran je u model sklopa NN koji je postigao koeficijent korelacije od 0,9414 za napon i 0,9354 za temperaturu katode.

U istraživanju Chávez-Ramíreza i sur. [40], stvoren je skup podataka od 1000 primjera s istim ulaznim podacima kao i skup podataka Napolija i sur. [39], uz dodatne ulazne vrijednosti za ubrizgavanje vode u katodu, temperaturu anode i temperaturu vode. U ovom slučaju korištena je NN s dva skrivena sloja koja je trenirana na 500 primjera, a validirana i testirana na dva različita skupa od po 250 primjera preostalog broja podataka. Autori su uspjeli postići koeficijent korelacije od 0,973 za napon i 0,983 za temperaturu katode.

Iz ovih dvaju istraživanja može se uočiti da, u slučajevima kada je dostupan mali broj podataka, kao u istraživanju Napolija i sur. [39], kombinacija ML modela s jednostavnom arhitekturom može poboljšati predviđanja modela. S druge strane, kada je dostupan veliki broj podataka, kao u istraživanju Chávez-Ramíreza i sur. [40], složeniji modeli mogu dati još preciznija predviđanja, ali isto tako su podložniji problemu *overfitting*-a. Ovi zaključci su dodatno potvrđeni u istraživanju Bicara i sur. [41], gdje je istraživani utjecaj broja skrivenih slojeva, metoda treniranja i različitog broja podataka. U ovom istraživanju, skup podataka generiran je korištenjem simuliranog PEMFC-a u MATLAB-u, što je omogućilo generiranje 50273 podatkovnih točaka u slučaju maksimalnog broja podataka. Broj skrivenih slojeva kretao se od 10 do 20 slojeva, a korištene su metode treniranja Levenberg-Marquardt i Bayesova regularizacija. Nakon provođenja nekoliko testova, zaključeno je da NN može precizno predvidjeti radne parametre PEMFC-a, ali da je proces njene izgradnje delikatan te podložan utjecaju različitih parametara.

Napredniji modeli na malim skupovima podataka rezultiraju *overfitting*-om, dok jednostavniji modeli na velikim skupovima podataka nisu u stanju postići male pogreške predviđanja. Stoga, prilikom izgradnje NN modela predviđanja za ove sustave, moraju se odabrati uravnotežene vrijednosti parametara kako bi se postigla točna predviđanja. Nadalje, predviđanja radnih parametara korištenjem NN našli su svoje mjesto i među drugim vodikovim tehnologijama. Milewski i sur. [42] u svom istraživanju testirali su NN za predviđanje napona SOFC-a, mijenjanjem brojem ulaznih parametara i broja neurona u skrivenom sloju. NN model je uspio postići relativnu pogrešku od 1% s jednostavnom NN 9-7-1 arhitekturom, te je pokazano da NN

model ima bolje performanse s povećanjem broja ulaznih parametara. Za ulazne podatke razmatrani su temperatura, sastav goriva, sastav oksidansa, debljina elektrolita, debljina anode i poroznost. Sličan rad objavili su Razbani i sur.[43], gdje je generiran skup podataka na SOFC-u u kojem su struja, temperatura zraka, protok vodika, protok dušika i protok zraka korišteni kao ulazni podaci za predviđanje napona članka i temperature na 5 različitih točaka unutar gorivnog članka. Kako je i inače poznato da povećanje temperature unutar gorivnog članka može biti pokazatelj kvara gorivnog članka, predviđanja različitih temperaturnih točaka zajedno s naponom članka može biti učinkoviti indikator stanja gorivnog članka. NN model postigao je prosječnu relativnu pogrešku od samo 0,2% za predviđanja napona i 0,05% za predviđanja temperature. Prije toga, Razbani i sur. [44], objavili su sličnu analizu koristeći računalnu dinamiku fluida (engl. *Computational Fluid Dynamics*, CFD) za simulaciju sustava i usporedili je s NN modelom. NN model uspio je dobiti točnije rezultate uz znatno manje računalnih resursa. Autori su, također, istaknuli da je glavno ograničenje NN modela, za postizanje dobre generalizacije i ekstrapolacije na različite slučajeve, nedostatak velike baze podataka radnih parametara uređaja, što je i najčešći problem kod primjene ML metoda u vodikovim tehnologijama.

Pristup testiranju točnosti predviđanja parametara korištenjem metode vijeća (engl. *committee*) NN, koji se sastoji od nekoliko NN s različitim brojem neurona u skrivenom sloju, primijenjen je na mikrobnom elektrolizatorskom članku (MEC) od strane Sewsynkera i sur. [45]. Metoda vijeća NN je skup više NN čiji se izlazi kombiniraju u jedan izlaz. Metoda vijeća NN korišten je za predviđanje proizvodnje vodika iz mikrobnog elektrolitičkog procesa na temelju vrste supstrata, koncentracije supstrata, pH, temperature, napona i konfiguracije reaktora. Model je treniran na 41 podatkovnoj točki i validiran na 9 točaka. Autori su izgradili NN modele s 6, 8, 11, 12 i 14 neurona u skrivenom sloju te su postigli koeficijent korelacije od 0,90, 0,81, 0,85, 0,70 i 0,80, redom. Primjenom metode usrednjavanja tih modela postignut je prosječni koeficijent korelacije od 0,85. Nakon toga, provedena je analiza osjetljivosti na metodi vijeća NN čiji rezultat ukazuje da na performanse MEC-a najviše utječu varijacije u vrsti supstrata, zatim napon, koncentracija supstrata, pH, konfiguracija MEC-a i temperatura, i to navedenim redoslijedom. Također, ML metode su primijenjene i na mikrobnom gorivnom članku (MFC) u radu Garga i sur. [46]. Autori su primijenili i usporedili tri ML metode: *Multi-Gene Genetic Programming* (MGGP), NN i SVR. ML metode korištene su za modeliranje i analizu utjecaja temperature i koncentracije željeznog sulfata na izlazni napon prije i nakon pokretanja. Korištena su četiri skupa podataka: 95 i 60 podatkovnih točaka za temperaturu prije i nakon pokretanja, te 76 i 60 podatkovnih točaka za koncentracije željeznog sulfata prije i nakon pokretanja. Svi skupovi podataka su nasumično izmiješani i podijeljeni u omjeru 4:1 za treniranje i testiranje modela. U svim primjerima, MGGP je pokazao najbolje performanse kako u vremenu računanja, tako i u točnosti, s koeficijentom korelacije većim od 0,95, osim za skup podataka s mjerenjima koncentracije željeznog sulfata nakon pokretanja, gdje je koeficijent korelacije bio 0,83.

Primjena ML metoda na skupove podataka koji ne dolaze iz laboratorijskog okruženja, testirana je u radu Entcheva i sur. [47]. Autori su prikupili skup podataka koji se sastoji od mjerenja radnih parametara SOFC-a povezanog s *Canadian Centre for Housing Technology*. Razvijeni su i uspoređeni modeli NN i *Adaptive Neuro Fuzzy Inference System* (ANFIS) u zadatku predviđanja struje i napona na temelju protoka goriva, temperature, protoka zraka, temperature ulaznog zraka, te protoka goriva, temperature izgaranja, protoka zraka i temperature ulaznog zraka u reaktoru. Oba modela postigla su relativnu postotnu pogrešku manju od 2%, ali NN je bio pet puta učinkovitiji u vremenu računanja u usporedbi s ANFIS-om.

U radu Özçelepa i sur. [48], korištene su NN i *Multiple Linear Regression* (MLR) za proučavanje utjecaja linearnog povećanja opterećenja na potrošnju vodika u PEMFC-u. Stvoren je skup podataka s 42 primjera ukupne energije, nagiba, najviše vrijednosti snage i potrošnje vodika, a korišten je za treniranje, validaciju i testiranje podataka s odgovarajućim podjelama od 70/15/15%. NN je uspjela nadmašiti MLR s koeficijentom korelacije od 0,9965 u usporedbi s 0,9545 za MLR. Modeli su zatim korišteni u analizi koja je pokazala da su se energetska i eksergetska učinkovitost smanjile za 6%, dok su se troškovi energije povećali za 13% s povećanjem nagiba snage.

Wilberforce i sur. [49] istraživali su utjecaj protoka vodika i kisika, te tlaka vodika i kisika na karakteristike serpentinskih kanala za dovod reaktanata u PEMFC-u. U istraživanju su predložene *Feed Forward Back Propagation* (FFBP) i *Group Method of Data Handling* (GMDH) za predviđanje vrijednosti napona i struje. Kao rezultat, metoda GMDH pokazala se točnijom od FFBP u predviđanjima napona, s koeficijentom korelacije od 0,99 u usporedbi s vrijednošću od 0,93 za FFBP. Međutim, FFBP se pokazao točnijim u predviđanju struje s koeficijentom korelacije od 0,98, u usporedbi s vrijednošću od 0,93 za GMDH. Uz to, na temelju ispitivanih parametara protoka vodika i kisika, te tlaka vodika i kisika, koji su korišteni i kao ulazni podaci za treniranje modela, predloženo je smanjenje neto gubitaka unutar gorivnog članka namještanjem nižeg protoka vodika od protoka kisika.

Strukturni parametri, kao što je širina serpentinskih kanala za dovod reaktanata u PEMFC-u, također se mogu integrirati u predviđanja performansi pomoću ML-a, a to su pokazali Seyhan i sur. [50]. U ovom istraživanju, autori su istražili učinak tri različite širine serpentinskih kanala na tri različite radne temperature. Eksperimenti su pokazali da je širina od 0,25 mm, u usporedbi sa standardnom širinom od 0,75 mm, postigla 20% veću izlaznu snagu PEMFC-a. Na temelju eksperimentalnih rezultata, autori su izgradili NN model koji je pokazao visoku korelaciju s eksperimentalnim podacima, što omogućuje daljnja istraživanja učinka i drugih vrijednosti širine kanala unutar istog raspona ulaznih parametara, bez potrebe za izvođenjem dodatnih eksperimenata.

Primjena ML metoda koje uključuju strukturne parametre za predviđanja performansi katalitičkog sloja (engl. *Catalyst Layer*, CL) PEMFC-a provedena je u istraživanju Khajeh-Hosseini-Dalasma i sur. [51]. U stanju potpunog zasićenja reaktanata, osam strukturnih parametara: debljina ionomernog filma koji pokriva aglomerat, radijus aglomerata, opterećenje platinom i ugljikom, sadržaj membrane, sadržaj penetracije sloja za difuziju plina i debljina CL-a, korišteni su za razvoj NN modela za predviđanje performansi. Nakon treniranja modela, *Analysis of means* (ANOM) i *Analysis of variance* (ANOVA) korištene su za analizu fizikalnih pojava korištenjem razvijenog modela. Rezultati analize su pokazali da debljina katodnog CL-a i volumen membrane u CL-u predstavljaju najznačajnije strukturne parametre koji utječu na performanse CL-a.

ML metode pronašle su svoje mjesto i u predviđanju polarizacijskih i impedancijskih krivulja, a koje su poznate kao jedne od glavnih metrika za evaluaciju performansi vodikovih tehnologija. Arama i sur. [52] u svom radu su predložili model senzora temeljen na NN koji predviđa impedanciju PEMFC-a, s ciljem poboljšanja dijagnostike hidratacije unutar PEMFC-a. Jednostavna NN s dva skrivena sloja primijenjena je za predviđanje impedancije PEMFC-a na temelju relativne vlažnosti reaktanata, vremena rada i impedancijske frekvencije. Model je uspješno predvidio impedancijsku krivulju i poboljšao kontrolu vlažnog protoka zraka u članku.

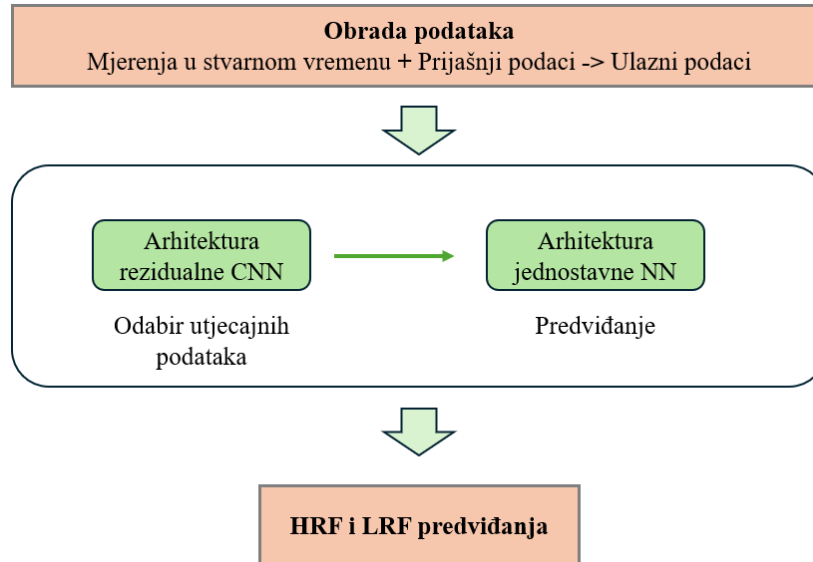
Han i sur. [53] usporedili su SVM i NN za predviđanje polarizacijske krivulje PEMFC-a, snage 1,2 kW, koji radi na čisti vodik i kisik u tzv. *dead-end* načinu rada. U ovom radu, ulazni tlak vodika i kisika, temperatura uređaja, relativna vlažnost kisika i struja odabrani su kao ulazni parametri za

treniranje modela predviđanja, jer su neovisni jedni o drugima te se mogu slobodno mijenjati prilikom prilagođavanja radnih uvjeta. Za fazu treniranja korištena su 923 uzorka, a za fazu testiranja 454 uzorka. Oba modela su unakrsno validirana na 10 presjeka podataka za treniranje, a performanse na testnom skupu postigle su koeficijent korelacije od 0,999 za NN i 0,98 za SVM.

Nastavljajući s analizom različitih primjena ML metoda za predviđanje radnih parametara PEMFC-a, u radu Goua i sur. [54] predložena je *Elman* NN optimizirana pomoću *Teaching-Learning-Based Optimization* (TLBO) i *Differential Evolution* (DE) za predviđanje polarizacijske krivulje. Autori su generirali 224 para vrijednosti struje i napona koji su korišteni kao ulazni i izlazni podaci pri četiri različita radna uvjeta. Od tih parova, 164 su korištena za treniranje hibridnog modela, a preostalih 60 parova za evaluaciju. Predviđanja modela praktički su se poklapala s empirijskim vrijednostima, čime je potvrđena točnost predložene metode.

Huo i sur. [55] istraživali su kombinaciju RF i CNN za predviđanje polarizacijskih krivulja. RF je korišten za odabir najutjecajnijih parametara, dok je CNN korišten za predviđanja. Autori su izradili skup podataka s 10000 točaka različitih performansi PEMFC-a, a primjenom RF-a su izdvojili 20 najutjecajnijih parametara, koji su dalje rekonstruirani u matricu 4 x 5 kako bi se omogućila primjena CNN-a za treniranje modela. Predložena metoda uspjela je dati točna predviđanja u većini testnih slučajeva, ali je pokazala i probleme s generalizacijskim sposobnostima zbog nedostatka eksperimentalnih podataka u određenim slučajevima.

Kako bi se poboljšala generalizacija i robusnost, drugi istraživači eksperimentirali su s kompleksnijim arhitekturama, jer generiranje više podataka obično nije izvedivo zbog visokih troškova eksperimenata. Jedan od primjera gdje je postignuta robusnost pomoću snažnije arhitekture je rezidualna CNN, prikazana na slici 3.1, koja uključuje rezidualne veze, a koristili su je Xie i sur. [56] za predviđanje karakteristične impedancijske frekvencije PEMFC-a. Odabrani su impedancijski otpori visokih frekvencija (engl. *High-Frequency impedance Resistance*, HFR) pri 2500 Hz i otpori niskih frekvencija (engl. *Low-Frequency impedance Resistance*, LFR) pri 10 Hz. Osam ulaznih signala (struja, napon, temperatura članka, ulazna temperatura anode i katode, stehiometrija zraka, ulazni tlak anode i katode) odabrani su kao ulazni podaci za predviđanje impedancije, a prethodno su transformirani u matricu 8 x 10 s impedancijom u sljedećem vremenskom koraku kao izlaznom vrijednosti. Nakon testiranja modela rezidualne CNN, postignute su vrijednosti srednje apsolutne postotne pogreške (engl. *Mean Absolute Percentage Error*, MAPE) od 0,802% za HFR i 1,386% za LFR, što je pokazalo poboljšanje od 23,02% i 4,11% u usporedbi s *Long Short-Term Memory* (LSTM) arhitekturom. Model je uspio postići točna predviđanja uz uvođenje šuma do 40 dB u testni skup podataka, što je potvrdilo njegovu robusnost.



Slika 3.1. Slijed koraka potrebnih za predikciju HRF i LRF modelom rezidualne CNN, prilagođeno iz [56]

Nastavljajući s predviđanjima impedancije pomoću ML metoda, Paciocco i sur. [57] primijenili su ML metode za predviđanje postizanja optimalne hidratacije u PEMFC-u. Podaci korišteni u ovom istraživanju sastojali su se od 85892 podatkovnih točaka, koje su prethodno obrađene i podijeljene u skupove za treniranje, validaciju i testiranje u omjerima od 72%, 12% i 16%, redom. Nakon obrade podataka i podjele, razvijeno je nekoliko ML modela na temelju konstruiranog skupa podataka za predviđanje otpora pri visokim frekvencijama. Nakon usporedbe, LSTM modeli pokazali su najbolje performanse i postigli točnost od 3,11% MAPE. Nakon toga, razvijen je model *K Nearest Neighbor* (KNN) za klasifikaciju optimalne gustoće struje hidratacije. Kombinacija ovih dviju metoda pružila je točna predviđanja i postigla vrijednosti preciznosti i odziva veće od 98%. Međutim, za razvoj modela otpornog na različite trendove u neviđenim podacima, bilo bi potrebno prikupiti veću količinu i širi raspon radnih parametara PEMFC-a.

Ipak, za specifične zadatke poput karakterizacije dinamike nastajanja mjehurića u eletkrolizi, manji skup podataka u kombinaciji s naprednim arhitekturama može biti dovoljan za postizanje točnih predviđanja. Ovo je prikazano u radu Colliard-Graneroa i sur. [58], gdje su testirane različite konfiguracije U-net arhitektura za segmentaciju mjehurića iz slikovnih podataka PEMWE-a. Treniran na samo 28 slika, najbolji model postigao je preciznost od 95%, odziv od 78% i F1-score od 86% na 7 primjera korištenih za validaciju modela. Nakon segmentacije, ovaj pristup omogućio je ekstrakciju parametara kao što su oblik, veličina, položaj mjehurića itd., što znatno doprinosi dijagnostici PEMWE-a.

Pregled analiziranih istraživanja sažet je u tablici 3.1, gdje je prikazano kako se ML modeli, od jednostavnih NN do složenijih arhitektura poput rezidualne CNN, mogu primijeniti za rješavanje različitih problema u dijagnostici i poboljšanju predviđanja u vodikovim tehnologijama, s naglaskom na važnost balansiranja složenosti modela s dostupnošću podataka kako bi se postigle točna predviđanja. Međutim, potrebna su daljnja unaprjeđenja u generalizaciji modela za širu industrijsku upotrebu.

Tablica 3.1. Sažetak pregledanih radova o primjeni strojnog učenja u predviđanju radnih parametara vodikovih tehnologija

Autor, god.	Sustav	Opis	Metoda	Skup podataka	Rezultati
Napoli i sur. [39], 2013.	PEMFC	Usporedba različitih arhitektura NN za predviđanje radnih parametara PEMFC-a na skupu podataka od 450 točaka	Sklop NN	Ekperimentalan	Metoda sklopa NN pokazala je najbolje performanse: koeficijent korelacije 0,9414 za napon i 0,9354 za temperaturu katode
Chavez-Ramirez i sur. [40], 2010.	PEMFC	Razvoj NN modela za predviđanje performansi PEMFC na skupu podataka od 1000 točaka	NN	Ekperimentalan	Model je uspio predvidjeti unutarnje mehanizme koji upravljaju PEMFC-om i predvidjeti njegovo ponašanje bez implementacije fizikalnih jednadžbi s koeficijentom korelacije 0,973 za napon i 0,983 za temperaturu katode
Bicer i sur. [41], 2016.	PEMFC	Istražuju se učinci skrivenih slojeva, metoda treniranja i broja uzoraka na performanse NN modela koji predviđa radne parametre PEMFC-a	NN	Simuliran	Nakon testiranja na skupu podataka od 50273 točaka rezultati pokazuju da su NN učinkovite za predviđanje izlaznih varijabli gorivnih članaka kao što su napon, struja i učinkovitost
Milewski i sur. [42], 2009.	SOFC	Razvoj NN modela za predviđanje napona SOFC-a	NN	Ekperimentalan	NN model s 9-7-1 arhitekturom može predvidjeti napon gorivnog članka bez implementacije fizikalnih jednadžbi uz relativnu pogrešku od 1%

Tablica 3.1. Sažetak pregledanih radova o primjeni strojnog učenja u predviđanju radnih parametara vodikovih tehnologija (nastavak)

Autor, god.	Sustav	Opis	Metoda	Skup podataka	Rezultati
Razbani i sur. [43], 2013.	SOFC	Razvoj NN modela za predviđanje napona i temperature SOFC-a	NN	Ekperimentalan	Rezultati predviđanja NN modela odstupaju 0,2% od prosječne relativne pogreške u odnosu na eksperimentalna mjerenja
Sewsynker i sur. [45], 2015.	MEC	Modeliranje proizvodnje vodika u MEC-u korištenjem vijeća NN na skupu podataka od 50 točaka	Vijeće NN	Ekperimentalan	Model je precizno modelirao nelinearni odnos između razmatranih fizikalno-kemijskih parametara MEC-a i proizvodnje vodika uz prosječni koeficijent korelacije od 0,85
Garg i sur. [46], 2014.	MFC	Procjena performansi MFC-a različitim ML metodama u slučajevima prije i poslije pokretanja uređaja	MGGP, NN, SVR	Ekperimentalan	MGGP metoda je postigla koeficijent korelacije od 0,95 u svim slučajevima osim jednog gdje je koeficijent korelacije bio 0,83
Entchev i sur. [47], 2007.	SOFC	Primjena ANFIS i NN za predviđanje performansi SOFC-a	ANFIS, NN	Ekperimentalan	Oba modela postigla su relativnu postotnu pogrešku manju od 2%, ali NN je 5 puta učinkovitiji u vremenu računanja u usporedbi s ANFIS-om
Ozçelep i sur. [48], 2020.	PEMFC	Analiza potrošnje vodika za linearno rastuće opterećenje gdje su eksperimentalni rezultati obrađeni s NN i MLR	NN, MLR	Simuliran	NN i MLR modelirali eksperimentalne podatke s koeficijentom korelacije 0,9965 za NN i 0,9545 za MLR, a uz to su energetska i eksergetska učinkovitost smanjene za 6%, dok je trošak energije povećan za 13% s povećanjem nagiba snage

Tablica 3.1. Sažetak pregledanih radova o primjeni strojnog učenja u predviđanju radnih parametara vodikovih tehnologija (nastavak)

Autor, god.	Sustav	Opis	Metoda	Skup podataka	Rezultati
Wilberforce i sur. [49], 2021.	PEMFC	Primjena različitih NN modela za određivanje napona i struje PEMFC-a	GMDMNN, FFBPNN	Ekperimentalan	Modeli su postigli dobre korelacije sa zanemarivim pogreškama, iako se GMDHNN pokazao bolji od FFBPNN u slučaju predviđanja napona, a obrnuto vrijedi za slučaj predviđanja struje
Seyhan i sur. [50], 2017.	PEMFC	PEMFC je modeliran za predviđanje izlazne struje korištenjem NN modela za slučajeve različitog oblika serpentina	NN	Ekperimentalan	NN model pokazao zadovoljavajuće rezultate za predviđanje izlazne struje i ima obećavajući potencijal za smanjenje broja eksperimenata i pronalaženje optimalnih radnih uvjeta i parametara
Khayeh-Hosseini-Dalasm i sur. [51], 2011.	PEMFC	Primjena NN modela za istraživanje utjecaja sloja katodnog katalizatora PEMFC-a	NN	Simuliran	Pokazalo se da je NN model sposoban predvidjeti aktivacijski prenapon katode CL za različite ulazne parametre, uključujući osam strukturnih parametara
Arama i sur. [52], 2021.	PEMFC	Predviđanje impedancije PEMFC-a pomoću modela senzora vlažnosti temeljenog na NN modelu	NN	Simuliran	Model senzora NN poboljšao je PEMFC hidrataciju i kontrolu protoka vlažnog zraka u gorivnom članku

Tablica 3.1. Sažetak pregledanih radova o primjeni strojnog učenja u predviđanju radnih parametara vodikovih tehnologija (nastavak)

Autor, god.	Sustav	Opis	Metoda	Skup podataka	Rezultati
Han i sur. [53], 2016.	PEMFC	SVM i NN modeli razvijeni su na skupu podataka od 1377 točaka za predviđanje i analizu performansi PEMFC-a koji radi na čistom kisiku	SVM, NN	Ekperimentalan	NN model je nadmašio SVM model s koeficijentom korelacije 0,999 u usporedbi s 0,98 za SVM, te je uspješno korišten za istraživanje utjecaja tlaka vodika i kisika, temperature, te relativne vlažnosti kisika na performanse PEMFC-a
Guo i sur. [54], 2019.	PEMFC	Kombinacija Elman NN i TLBO-DE za predviđanje parametara PEMFC-a	Elman NN, TLBO-DE	Ekperimentalan	Predložena metoda testirana je na podatkovnom skupu od 224 točke te uspjeva predvidjeti napon u različitim radnim uvjetima s visokom vjerodostojnošću
Huo i sur. [55], 2021.	PEMFC	Korištenje RF algoritma za odabir ulaznih podataka modela iz skupa podataka s 10000 točaka, te korištenje CNN za predviđanje polarizacijske krivulje	RF, CNN	Ekperimentalan	Predviđene polarizacijske krivulje se slažu sa stvarnim krivuljama

Tablica 3.1. Sažetak pregledanih radova o primjeni strojnog učenja u predviđanju radnih parametara vodikovih tehnologija (nastavak)

Autor, god.	Sustav	Opis	Metoda	Skup podataka	Rezultati
Xie i sur. [56], 2023.	PEMFC	Rezidualna CNN primjenjuje se za procjenu karakteristične frekvencijske impedancije na temelju osam mjerljivih signala sustava gorivnih članaka u vozilu	Rezidualna CNN	Eksperimentalan	Rezultati pokazuju da rezidualna mreža može postići procjenu HFR i LFR s MAPE od 0,911%, odnosno 1,610%, čak i pri šumu od 40 dB
Paciocco i sur. [57], 2023.	PEMFC	Metode ML primjenjuju se za HFR i optimalne gustoće struje putem parametara izmjerenih elektrokemijskom impedancijskom spektroskopijom	LSTM, NN, KNN, RF, LR	Eksperimentalan	Model je razvijen na skupu podataka od 85892 točaka, te je za regresiju LSTM model dao najbolja HFR predviđanja s MAPE od 3,11%, dok je KNN metoda uspjela postići vrijednosti preciznosti i odziva veće od 98%
Colliard-Granero i sur. [58], 2017.	PEMWE	Primjena U-Net metode za analizu dinamike pojave mjehurića pri elektrolizi pomoću slika	U-Net	Eksperimentalan	Model je uspio postići preciznost od 95%, odziv od 78%, a F1-score od 86%, što je omogućilo točnu segmentaciju mjehurića, predviđanje područja pojave mjehurića, distribucije veličine, vjerojatnosti položaja mjehurića i analizu oblika pojedinačnog mjehurića

4. PRIMJENA STROJNOG UČENJA U DEGRADACIJI, DIJAGNOSTICI I PROGNOSTICI VODIKOVIH TEHNOLOGIJA

Ovo poglavlje nudi sveobuhvatan pregled trenutnih istraživanja primjene ML metoda za predviđanje degradacije, dijagnostike i prognostike vodikovih tehnologija na razini uređaja, od jednostavnijih metoda do složenijih, pružajući uvid u njihove mogućnosti i postignute rezultate.

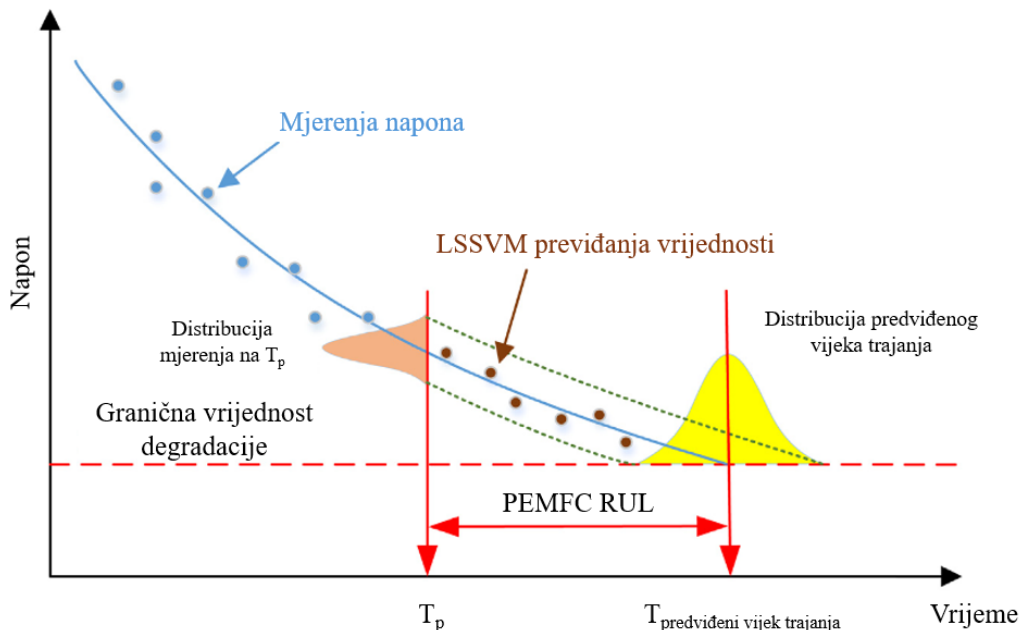
Primjerice, Bahr i sur. [59] primijenili su jednostavnu NN za predviđanje degradacije PEMWE-a na temelju polarizacijskih krivulja. Ubrzani eksperiment degradacije proveden je na ispitnoj stanici PEMWE-a snage 40 kW, gdje je sustav radio 384 sata u pet različitih radnih uvjeta. Polarizacijske krivulje mjerene su svakih 24 sata, što je rezultiralo sa 16 primjera koji su dalje korišteni za treniranje i testiranje modela. Jednostavni model NN s dva skrivena sloja zatim je stvoren za svaki od pet različitih radnih profila, s ulaznim podacima struje sustava, temperature sustava i vremena rada, dok je izlazni podatak bio razlika napona u odnosu na početnu točku odgovarajuće postavke rada. Zadovoljavajuća točnost postignuta je na svim skupovima podataka, ali je potrebno detaljnije ispitivanje većeg skupa podataka kako bi se pouzdano evaluirala primjena ML metoda.

U novijem radu, Hayatzadeh i sur. [60] primijenili su NN i SVR za predviđanje utjecaja temperature na degradaciju različitih katalizatora anode u PEMWE-u. Prikupljeno je 5 skupova podataka koji su korišteni za treniranje modela, s brojem podataka u rasponu od 90 do 500 primjera. Svi skupovi podataka podijeljeni su u omjeru 80:20 za treniranje i testiranje. Nakon što su modeli trenirani i testirani na svim skupovima podataka, pokazalo se da je SVR u početku bio slabiji u usporedbi s NN-om, ali nakon optimizacije svojih hiperparametara pomoću genetskog algoritma (engl. *Genetic Algorithm*, GA), postigao je usporedivu točnost s NN-om, pri čemu su oba modela postigla korijen srednje kvadratne pogreške (engl. *Root Mean Squared Error*, RMSE) od 0,008 na testnim skupovima podataka.

Morando i sur. [61] u svom radu su istražili primjenu *Echo State Network* (ESN) za predviđanje degradacije PEMFC-a. Predložena metoda koristi Hurst-ov koeficijent za filtriranje signala kako bi dobila komponentu detalja i komponentu aproksimacije signala. Komponenta aproksimacije i komponenta detalja se zatim koriste kao ulazni podaci za optimizaciju dviju ESN. Prva ESN je stvorena i optimirana kako bi dala najbolje rezultate predviđanja za komponentu aproksimacije, dok druga ESN ima za cilj modelirati ponašanje komponente detalja preostalog dijela i optimirana je sukladno tome. Ovaj proces se iterativno ponavljao, a konačno, predviđeni signal se dobio iz zbroja predviđanja definiranih ESN-ova. Model je uspio postići MAPE manji od 5% nakon treniranja na samo 340 sati eksperimentalnih podataka. Unatoč postizanju zadovoljavajuće točnosti predviđanja, ovaj pristup zahtijeva pažljivo rukovanje algoritmom jer uvodi povratnu vezu između ulaznih i izlaznih podataka, što implicira propagaciju pogreške s iteracijama i može dovesti do velikog odstupanja konačnih rezultata.

Cheng i sur. [62] u svom su radu predložili hibridnu metodu predviđanja degradacije PEMFC-a. Prognostički okvir sastojao se od procesa treniranja i predviđanja. Tijekom procesa treniranja, model je radio predviđanje pomoću *Least Square Support Vector Machine* (LSSVM) metode trenirane na unaprijed obrađenim vrijednostima napona. Istovremeno, *Regularized Particle Filter* (RPF) metoda primijenjena je za praćenje stanja sustava koristeći izmjerene vrijednosti napona. Ilustracija korištenog algoritma prikazana je na slici 4.1 U prognostičkom procesu, LSSVM model predviđao je buduće vrijednosti napona PEMFC-a koji su zatim služili kao novi uvidi u sustav, a

koji su zatim integrirani u RPF. RPF je kombinirao predviđanja LSSVM-a i dodatna promatranja budućeg stanja sustava sve dok ne bi dosegnuo unaprijed definirani prag kvara. Na kraju, pomoću RPF-a izražena je distribucija vjerojatnosti preostalog vijeka trajanja (engl. *Remaining Useful Lifetime*, RUL) s određenim faktorom nesigurnosti. Učinkovitost predložene metode potvrđena je na temelju skupa podataka PEMFC-a iz FCLAB Research Federation, koji sadrži 1155 podatkovnih točaka iz 1154-satnog eksperimenta degradacije provedenog u statičkim uvjetima, gdje je predloženi hibridni model uspio postići vrlo dobre rezultate. Međutim, glavno ograničenje istraživanja, koje su istaknuli i autori, bilo je izvođenje eksperimenta u statičkim uvjetima, što se rijetko (ili nikako) događa u stvarnosti.



Slika 4.1. Predviđanje degradacije PEMFC-a temeljeno na LSSVM-RPF, prilagođeno iz [62]

Predviđanje degradacije u dinamičkim uvjetima predstavljeno je u radu Vichard i sur. [63], gdje je ESN odabran kao algoritam za predviđanje. 5000 sati podataka za izradu modela generirano je korištenjem AIRCELL sustava tvrtke H2SYS na kojem su simulirana ciklička opterećenja koja bi PEMFC mogao iskusiti ako bi bio implementiran u vozilu. 60% podataka korišteno je za treniranje modela, a preostalih 40% za testiranje. Budući da je ovo istraživanje provedeno pod različitim radnim uvjetima, radna temperatura, radno vrijeme i izlazni napon u prethodnom stanju odabrani su kao utjecajni parametri i korišteni su kao ulazni podaci modela. Nakon treniranja i testiranja modela, ESN model je postigao normaliziranu srednju kvadratnu pogrešku (engl. *Normalized Root Mean Squared Error*, NRMSE) od 0,098 za predviđanje 2000 sati rada pri različitim vrijednostima radne temperature s vremenom računanja od oko 2 sekunde.

Predviđanje degradacije na temelju većeg broja radnih parametara predstavljeno je u radu Chen i sur. [64] o predviđanju degradacije PEMFC-a korištenjem *Grey Neural Network* metode, čiji su početni parametri optimizirani s *Particle Swarm Optimization* (PSO) algoritmom. Struja, ulazna temperatura, ulazni tlak vodika i ulazna relativna vlažnost odabrani su za ulazne podatke, dok je izlazni napon odabran kao izlazni podatak. Za treniranje i testiranje modela autori su generirali 3

skupa podataka. Prvi skup podataka stvoren je na temelju 800 sati eksperimenta degradacije u statičkim uvjetima. Drugi je temeljen na eksperimentu degradacije pod dinamičkom strujom opterećenja s visokofrekventnim valovima struje koji je trajao 550 sati. Treći skup podataka temeljen je na trogodišnjem eksperimentu degradacije PEMFC-a u poštanskom električnom vozilu s gorivnim člancima u stvarnim uvjetima. Na prva dva skupa podataka primijenjena je *Sliding Window* tehnika s veličinom intervala od 5 sati, dok je na trećem veličina intervala bila 1,5 sati. Model je postigao vrijednost MAPE od 0,29% na prvom skupu podataka nakon treniranja na samo 200 sati podataka i vrijednost MAPE od 0,3% na drugom skupu podataka nakon treniranja na samo 100 sati podataka. Na trećem skupu podataka model je postigao vrijednost MAPE od 1,04% zbog povećane složenosti trećeg skupa podataka.

Ma i sur. [65] u svom su radu istraživali sposobnosti predviđanja LSTM modela za dugoročno i kratkoročno predviđanje degradacije. Stvorena su 4 skupa podataka koja opisuju po 400 sati na NEXA Ballard PEMFC-u pod različitim statičkim uvjetima rada za testiranje LSTM modela u slučaju kratkoročnog predviđanja degradacije. Peti skup podataka za testiranje dugoročnog predviđanja degradacije LSTM modela stvoren je na PM200 PEMFC-u tijekom eksperimenta degradacije koji je trajao 10000 sati. Skupovi podataka od 400 sati podijeljeni su na 225 sati za treniranje i 175 sati za testiranje, dok je skup podataka od 10000 sati podijeljen na 6800 sati za treniranje i 3200 sati za testiranje. Na svim skupovima podataka, LSTM model postigao je točna predviđanja s RMSE-om u rasponu od 0,2291 do 0,1238, dokazujući svoju sposobnost za predviđanje degradacije u kratkoročnom i dugoročnom slučaju.

U radu Zuo i sur. [66] uspoređene su *Gated Recurrent Unit* (GRU) i LSTM arhitekture modela u predviđanju degradacije PEMFC-a. LSTM i GRU arhitekture omogućuju opisivanje dugoročnih ovisnosti unutar sekvencijalnih podataka selektivnim fokusiranjem na specifične dijelove ulazne sekvence. Eksperiment s dinamičkim ciklusom opterećenja proveden je tijekom više od 1000 sati, a nakon primjene metode obrade izmjerenih podataka, konstruirana su dva skupa podataka za validaciju modela. Prvi skup podataka konstruiran je nakon prethodne obrade rezultata testa izdržljivosti. Vrijeme eksperimenta, vrijednost struje i naponske vrijednosti u ciklusu dinamičkog opterećenja gorivnog članka odabrani su kao ulazni podaci modela, dok je izlazni podatak modela bio izlazni napon PEMFC-a. Za drugi skup podataka, iz dinamičkih radnih uvjeta, prethodnih 5 vrijednosti napona korištene su kao ulazni podaci, a izlazni podatak je bio izlazni napon. Prvih 600 sati oba skupa podataka korišteno je za treniranje modela, dok je ostatak korišten za validaciju. Na prvom skupu podataka, LSTM i GRU modeli postigli su RMSE od 0,016, odnosno 0,015. Za drugi skup podataka razvijen je samo LSTM model koji je postigao RMSE od 0,004.

Nastavljajući s predviđanjem degradacije koristeći LSTM arhitekturu, Liu i sur. [67] uspjeli su postići slične rezultate točnosti kao Zuo i sur. [66], s RMSE od 0,003. Metoda *Locally Weighted Scatterplot Smoothing* (LWSS) učinkovito je očuvala izvorni trend podataka, uz uklanjanje šuma iz podataka. Ova metoda primijenjena je na 1154-satni eksperimentalni skup podataka degradacije u statičkim uvjetima. Prvih 550 sati korišteno je za treniranje modela, a preostali sati za testiranje.

Na temelju analize prethodnih istraživanja, dokazano je da modeli s LSTM arhitekturom mogu predvidjeti fenomene degradacije, ali se robusnost i generalizacija moraju dodatno unaprijediti poboljšanjima u dizajnu arhitekture i korištenjem više podataka. Primjer takvih poboljšanja predstavljen je u radu Zuo i sur. [68], gdje je LSTM model stvoren i testiran na 1154-satnom testu degradacije u dinamičkim uvjetima. Izmjereni podaci su obrađeni pomoću Sawitzky-Goliath filtera i rekonstruirani u ulazne podatke primjenom tehnike *Sliding Window* u 5-satnom intervalu,

uz izlazni napon, struju gorivnog članka i protok rashladne vode. Osim treniranja na više radnih parametara, robusnost modela dodatno je poboljšana uvođenjem *Dropout layera* i *Mini-batches* u arhitekturu modela. Model je zatim primijenjen na skupovima podataka za treniranje i testiranje u omjerima 25%, 50% i 75%, sa i bez *Dropout layer-a*. Najbolja postignuta vrijednost RMSE od 0,0023 uočena je kada je model treniran na 75% podataka s *Dropout layer-om*. Nadalje, ovaj model uspio je postići RMSE od 0,0051 kada je treniran na samo 25% podataka, što pokazuje da ovaj model uspijeva predvidjeti degradaciju PEMFC-a s relativno malom količinom podataka za treniranje.

Međutim, jedan od problema koji se pojavljuju prilikom generiranja skupova podataka je činjenica da često isti gorivni članci koji rade pod istim uvjetima različito degradiraju. Ovaj problem je istaknut u radu Ma i sur. [69], gdje je kombinacija više ML metoda primijenjena kako bi se stvorio model koji može upravljati tim neočekivanim varijacijama i poboljšala robusnost modela. Prvo, kada su podaci iz novog PEMFC generirani, obrađeni su *Self-optimized time scale local weighted regression* modelom. Podacima su zatim uspoređene sličnosti kosinusne udaljenosti s povijesnim podacima prethodno testiranih PEMFC-a. Na temelju tih informacija, novi podaci su generirani kombinacijom *Stacked autoencoder* (SAE) metode i *Hybrid transfer learning* strategije. Nakon što su novi podaci generirani, na temelju sličnosti povijesnih podataka, korištena je arhitektura složene LSTM s promjenjivom duljinom ulazne sekvence za izgradnju modela predviđanja. Model je testiran i uspoređen s drugim arhitekturama na 5 testnih skupova podataka, te je postignuta prosječna relativna točnost od 0,9519. Važno je napomenuti da je model sa standardnom LSTM arhitekturom imao prosječnu relativnu točnost od 0,9496, ali s polovicom vremena računanja u usporedbi s LSTM arhitekturom s promjenjivom duljinom ulazne sekvence, što može biti važan faktor pri razmatranju mogućnosti korištenja tih modela za praćenje u stvarnom vremenu i predviđanju degradacije.

Predstavljena istraživanja, sažeta u tablici 4.1, naglašavaju izazove predviđanja degradacije u dinamičkim uvjetima i ističu važnost navedenih modela za praktične primjene. LSTM arhitektura pokazala se najčešće korištenom za razvoj modela zbog svoje sposobnosti opisivanja kratkoročnih i dugoročnih ovisnosti. Međutim, kako bi se poboljšala robusnost i generalizacija modela, potrebno je izgraditi raznovrsne skupove podataka koji uključuju širok broj radnih parametara.

Tablica 4.1. Sažetak pregledanih radova o primjeni strojnog učenja u degradaciji, dijagnostici i prognostici vodikovih tehnologija

Autor, God	Sustav	Opis	Metoda	Skup podataka	Rezultati
Bahr i sur. [59], 2020.	PEMWE	Predviđanje degradacije PEMWE pomoću NN na skupu podataka od 16 točaka dobivenih dijeljenjem 348 sati mjerenja tijekom eksperimenta podijeljenog u 24-satne intervale	NN	Eksperimentalan	NN uspješno predviđa degradaciju iz polarizacijskih krivulja

Tablica 4.1. Sažetak pregledanih radova o primjeni strojnog učenja u degradaciji, dijagnostici i prognostici vodikovih tehnologija (nastavak)

Autor, God	Sustav	Opis	Metoda	Skup podataka	Rezultati
Hayatzadeh i sur. [60], 2024.	PEMWE	Usporedba SVR i NN za predviđanje degradacije PEMWE-a na 5 različitih skupova podataka	SVR, GA, NN	Eksperimentalan	SVR, optimiran GA i NN uspijevaju predvidjeti degradaciju s RMSE od 0,008
Morando i sur. [61], 2017.	PEMFC	RUL predviđanje pomoću ESN-a	ESN	Eksperimentalan	ESN uspijeva postići MAPE manji od 5% nakon treniranja na samo 340 sati eksperimentalnih mjerenja
Cheng i sur. [62], 2018.	PEMFC	Primjena hibridne prognostičke metode za PEMFC temeljene na LSSVM i RPF na skupu podataka od 1154 eksperimentalna mjerenja	LSSVM, RPF	Eksperimentalan	Predložena hibridna metoda uspješno uspijeva predvidjeti PEMFC RUL, s faktorom nesigurnosti predviđanja
Vichard i sur. [63], 2020.	PEMFC	RUL predviđanje pomoću ESN-a na podatkovnom setu od 5000 sati rada	ESN	Eksperimentalan	Model postiže NRMSE 0,098 za predviđanje 2000 sati radnog vremena na osnovu prijašnjih 3000 sati za različite vrijednosti radne temperature
Chen i sur. [64], 2019.	PEMFC	Primjena <i>Grey</i> NN u kombinaciji s PSO za predviđanje degradacije PEMFC-a u statičkim i dinamičkim radnim uvjetima	PSO- <i>Grey</i> NN	Eksperimentalan	Predložena metoda uspješno predviđa degradaciju za PEMFC s MAPE ispod 1% u statičkim i dinamičkim radnim uvjetima
Ma et al. [65], 2018.	PEMFC	Primjena LSTM modela za predviđanje degradacije dvije različite vrste PEMFC-a na pet eksperimentalnih skupova podataka starenja	LSTM	Eksperimentalan	Rezultati pokazuju da predloženi LSTM model može točno predvidjeti degradaciju PEMFC-a, uz RMSE manji od 0,22 u svih 5 razmatranih slučajeva

Tablica 4.1. Sažetak pregledanih radova o primjeni strojnog učenja u degradaciji, dijagnostici i prognostici vodikovih tehnologija (nastavak)

Autor, God	Sustav	Opis	Metoda	Skup podataka	Rezultati
Zuo i sur. [66], 2021.	PEMFC	Primjena LSTM i GRU modela za predviđanje degradacije izlaznog napona PEMFC-a na temelju izvornih podataka o dugotrajnom ispitivanju trajnosti ciklusa dinamičkog opterećenja	LSTM, GRU	Eksperimentalan	Nakon treniranja na skupu podataka od 600 sati rada, LSTM i GRU modeli postižu RMSE manji od 0,016 za predviđanja degradacije za sljedećih 400 sati
Liu i sur. [67], 2019.	PEMFC	Predviđanje PEMFC RUL-a, temeljeno na LSTM, uz korištenje različitih metoda za obradu podataka	LSTM	Eksperimentalan	Predložena metoda može brzo i točno predvidjeti preostali životni vijek gorivnog članka, uz RMSE od 0,003
Zuo i sur. [68], 2021.	PEMFC	Predviđanje degradacije PEMFC-a primjenom LSTM modela i Savitzky-Goliath filtera	LSTM	Eksperimentalan	Rezultati pokazuju da predloženi model može precizno predvidjeti degradaciju gorivnih članaka uz RMSE od 0,0051 treniranjem na samo 25% podataka
Ma et al. [69], 2021.	PEMFC	Primjena <i>Hybrid transfer learning</i> strategije u kombinaciji sa SAE za predviđanje degradacije PEMFC-a	LSTM, SAE	Eksperimentalan	Predložena metoda testirana je na 5 različitih skupova podataka i na svima uspijeva postići prosječnu relativnu točnost od 0,9519 s dvostruko manjim vremenom računanja, u usporedbi s LSTM modelom čija je prosječna relativna točnost iznosila 0,9496

5. PRIMJENA STROJNOG UČENJA U OTKRIVANJU KVAROVA VODIKOVIH TEHNOLOGIJA

Ovo poglavlje pruža pregled trenutnih istraživanja o primjeni ML metoda za otkrivanje kvarova u vodikovim tehnologijama na razini uređaja, naglašavajući njihovu učinkovitost u poboljšanju točnosti dijagnoze kvarova i pouzdanosti sustava.

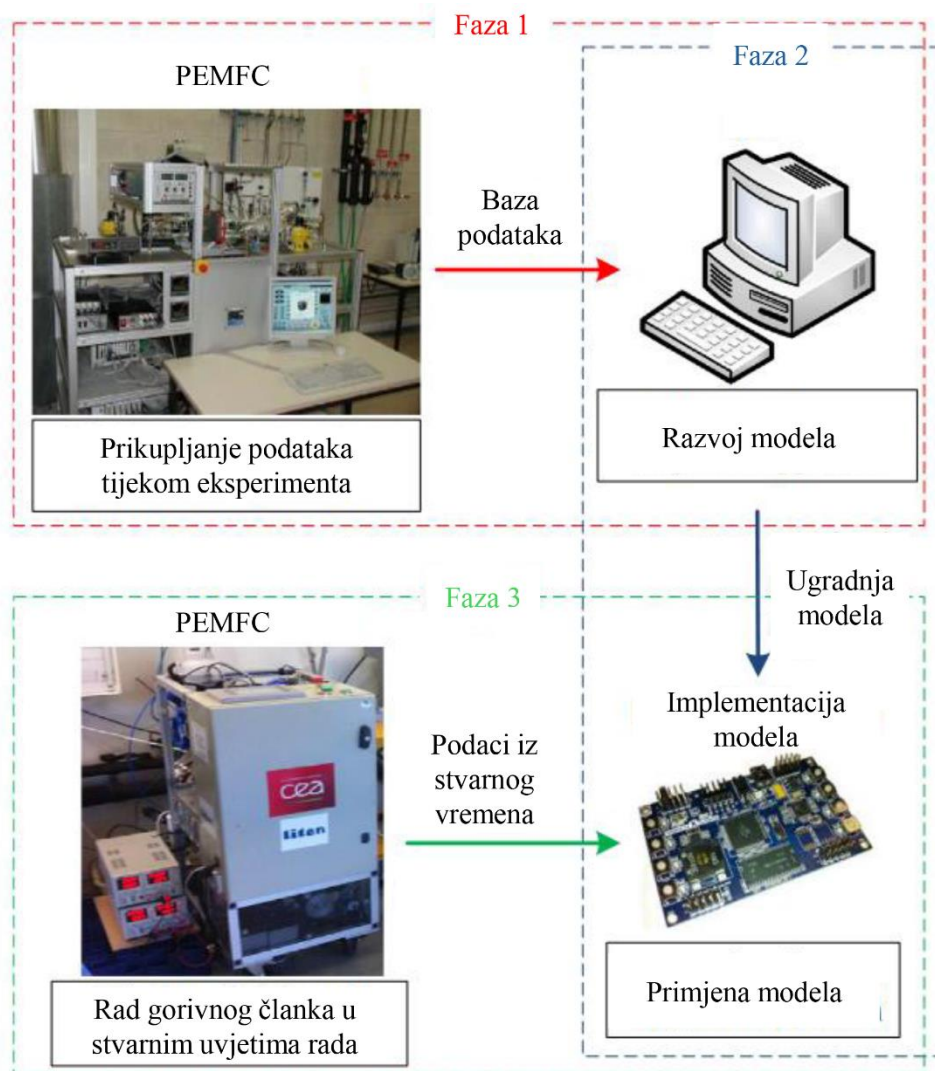
Xue i sur. [70] primijenili su jednostavnu NN s jednim skrivenim slojem za identifikaciju uobičajenih radnih uvjeta, kvarova elektroda i curenja plina u SOFC-u. Skup podataka od 390 normaliziranih točaka, generiranih pri različitim radnim uvjetima, je simuliran, a 330 od tih točaka korišteno je za treniranje modela, dok je preostalih 60 korišteno za testiranje. Struja, temperatura, protok goriva i omjer goriva u sastavu plina korišteni su kao ulazne varijable za otkrivanje kvarova. Tijekom treniranja, primijenjena je 11-kratna unakrsna validacija, a model je uspio postići točnost od 95% u predviđanju na testnom skupu podataka.

Laribi i sur. [71] također su u svom radu primijenili NN, ali za razvoj impedancijskog modela koji može otkriti plavljenje i isušivanje PEMFC-a. Model s dva skrivena sloja korišten je za predviđanje radnih parametara modela na temelju relativne vlažnosti i vremena rada. Iz prikaza korelacije između testnih podataka i modela predviđanja, pokazano je da je model bio sposoban dati točna predviđanja, a ovaj robustan model dodatno je poboljšán s tzv. *Constant Phase Element* (CPE) metodom koja im je omogućila detaljnu analizu utjecaja vlažnosti zraka na upravljanje vodom u gorivnom članku.

Kako bi dodatno poboljšali generalizaciju i stabilnost predviđanja NN, Shao i sur. [72] su u svom radu predložili metodu NN ansambla za otkrivanje kvarova u PEMFC-u. Metoda NN ansambla poboljšava generalizaciju i stabilnost predviđanja treniranjem nekoliko NN na istom zadatku i kombiniranjem njihovih izlaznih podataka. Skup podataka za ispitivanje ove metode dobiven je izvođenjem eksperimenta dinamičkog modela PEMFC-a koji je stvoren i simuliran korištenjem MATLAB-a. U eksperimentu su odabrana četiri kvara za testiranje predloženog NN ansambl modela: kvarovi sustava hlađenja, miješanje goriva, kvarovi sustava za dovod zraka i kvarovi sustava za dovod vodika, a odabrani su upravo ovi kvarovi koje u praksi nije lako izmjeriti i otkriti standardnom laboratorijskom opremom. Trenirane su četiri NN s jednim skrivenim slojem, ali različitim brojem neurona te različitim ulaznim i izlaznim podacima. Njihovi su izlazi kombinirani korištenjem Lagrangeovog multiplikatora kako bi se dobila konačna predviđanja. Kao rezultat, predloženi NN ansambl uspio je otkriti kvarove s točnošću od 93,24%. Štoviše, metoda ansambla omogućila je veliku fleksibilnost jer se struktura ovog modela može lako mijenjati, što omogućuje dobru generalizaciju u različitim simuliranim slučajevima.

Primjer korištenja SVM-a za otkrivanje kvarova predstavljen je u radu Costamagna i sur. [73] na SOFC-u, te Li i sur. [74] na PEMFC-u. Costamagna i sur. [73], u svojoj implementaciji SVM-a, fokusirali su se na problem rada SOFC-a izvan projektiranih uvjeta. Autori su istaknuli da se radni uvjeti SOFC-a, na kojima je model treniran, mogu promijeniti tijekom njegovog vijeka trajanja. Stoga, predložen je SVM model koji poboljšava točnost u neočekivanim uvjetima. Eksperimentalni sustav, koji se sastojao od reformera, SOFC-a i komore izgaranja, korišten je za generiranje podataka. Degradacija uređaja, curenje zraka, curenje goriva i degradacija reformera odabrani su kao kvarovi za otkrivanje na temelju 10 radnih parametara SOFC-a. Za treniranje modela korišteno je 200 primjera mjerenja u projektiranim uvjetima, a dodatnih 200 za testiranje

u uvjetima rada izvan i unutar projektiranih uvjeta. Ova metoda pokazala se uspješnom, postižući točnost između 85% i 94% u uvjetima rada izvan projektiranih vrijednosti, što je bilo blizu točnosti od 95% postignute u projektiranim uvjetima rada. S druge strane, Li i sur. [74] u svojoj implementaciji SVM-a za otkrivanje kvarova usredotočili su se na primjenu kod električnih vozila s gorivnim člancima (FCEV), što zahtijeva točnost i detekciju u stvarnom vremenu. Za postizanje tog cilja, prvo je stvoren skup podataka na temelju mjerenja izlaznog napona svakog članka unutar sklopa PEMFC-a od 64 članka, a koji su korišteni kao ulazni podaci za SVM klasifikaciju. Definirana su četiri slučaja kvara u kojima radni parametri odstupaju od uobičajenih uvjeta rada. Općenito, rezultati klasifikacije korišteni su izravno kao rezultati dijagnoze, ali za poboljšanje pouzdanosti predviđanja autori su implementirali dodatno pravilo koje koristi slijed rezultata klasifikacije umjesto jednog rezultata za određivanje trenutnog stanja gorivnog članka. Isti model zatim je implementiran na uređaj koji je omogućio *online* validaciju razvijenog modela. Ilustracija različitih faza razvoja prikazana je na slici 5.1. Točnost dijagnostike u *online* implementaciji iznosila je 93,99%, što potvrđuje da predloženi model može uspješno izvršavati zadatak predviđanja stanja PEMFC-a i otkrivanje kvarova.



Slika 5.1. Koraci razvoja sustava za online detekciju kvarova PEMFC-a, prilagođeno iz [74]

Spomenuti problem otkrivanja kvarova, temeljen na mjerenjima u jednoj vremenskoj točki koja zanemaruje ovisnosti prethodnih mjerenja, može se riješiti korištenjem ML metoda koje se mogu koristiti na sekvencijskim podacima. To je prikazano u radu Gu i sur. [75], gdje je cilj bio otkrivanje plavljenja korištenjem LSTM modela. Sposobnost predviđanja LSTM modela na osnovu sekvencijskih vremenskih podataka omogućila je učinkovitu dijagnozu plavljenja PEMFC-a na temelju mjerenja radnih parametara. Skup podataka korišten za treniranje dobiven je iz stvarnih eksperimentalnih podataka P390 sustava gorivnih članaka. Nakon toga, testiranje je provedeno implementacijom modela na uređaj i provođenjem *online* validacije na istom P390 sustavu gorivnih članaka, pri čemu je model pokazao vrlo dobro slaganje s eksperimentalnim rezultatima. Pokazano je da LSTM model može učinkovito dijagnosticirati kvarove plavljenja, te pomoći sustavu upravljanja da reagira na vrijeme i izbjegne pojavu kvarova. Implementacija ovakvih modela može omogućiti značajno smanjenje troškova održavanja sustava gorivnih članaka jer se može izbjeći instalacija mnogih senzora koji su inače potrebni za otkrivanje kvarova plavljenja. Međutim, modeli trebaju biti trenirani na većem broju podataka pod različitim radnim uvjetima kako bi se poboljšala njihova točnost i sposobnost generalizacije.

Istraživanje Zheng i sur. [76] uvelo je *Reservoir Computing* metodu koja je simulirala virtualnu NN, modeliranu nelinearnom jednadžbom kašnjenja za otkrivanje različitih kvarova u PEMFC-u. Primjena i učinkovitost ove metode potvrđene su na pet slučajeva kvarova: trovanje ugljikovim monoksidom, smanjena brzina protoka zraka, neispravno hlađenje i degradacija performanse. Razvijeni model uspio je otkriti sve navedene kvarove s točnošću klasifikacije od 99,88% za *offline* treniranje i 92,43% na neviđenim podacima. Daljnja ispitivanja provedena su na različitim uzorcima skupa podataka i pokazalo se da je predložena metoda bila pod utjecajem veličine i redoslijeda skupa podataka, ali je i dalje uspjela postići točnost od 88% u najgorem simuliranom slučaju od svih koji su se razmatrali.

Zhang i sur. [77] istaknuli su nedostatke mnogih modela koji uzimaju u obzir otkrivanje samo jedne vrste kvara, jer je i u praksi puno češća pojava više kvarova istovremeno. Kako bi riješili ovaj problem, u svom radu koristili su *Stacked sparse autoencoder* (SSAE) metodu za predviđanje više kvarova istovremeno na SOFC-u. Skup podataka za razvoj modela stvoren je simuliranjem SOFC-a u MATLAB-u, i to na 80000 primjera pojedinačnih kvarova i 1000 istovremenih kvarova. Za predviđanje je korišteno 16 mjerenja, a SSAE je postigao točnost od 89% na testnom skupu podataka, nadmašivši NN koje su postigle točnost od 87%. Na istom testnom skupu podataka, SVM metoda je uspjela otkriti samo 62% kvarova, što pokazuje kako SSAE omogućuje maksimalno iskorištavanje originalnih varijabli sustava i korištenje neoznačenih podataka.

Primjena različitih ML metoda za otkrivanje kvarova u vodikovim tehnologijama pokazuje obećavajuće rezultate za poboljšanje točnosti dijagnostike kvarova i pouzdanosti sustava. Od NN do SVM, te naprednih tehnika poput LSTM-a, ove metode su se pokazale učinkovitim u različitim sustavima vodikovih tehnologija. Dodatno, nadogradnje kao što su korištenje sekvencijskih vremenskih podataka i predviđanje više kvarova istovremeno pokazuju obećavajući potencijal za buduće primjene u otkrivanju kvarova, ali zahtijevaju i više podataka za treniranje kako bi se poboljšala njihova točnost i sposobnost generalizacije.

Pregled analiziranih istraživanja u ovom poglavlju sažet je u Tablici 5.1.

Tablica 5.1. Sažetak pregledanih radova o primjeni strojnog učenja u otkrivanju kvarova vodikovih tehnologija

Autor, God	Sustav	Opis	Metoda	Skup podataka	Rezultati
Xue i sur. [70], 2019.	SOFC	Primjena NN modela za otkrivanje kvarova SOFC	NN	Simuliran	Nakon što je testirano 60 uzoraka s dva stanja kvara u normalnim radnim uvjetima, rezultati su pokazali da je stopa prepoznavanja kvara 95%
Laribi i sur. [71], 2019.	PEMFC	Primjena NN modela za detekciju kvara plavljenja i isušivanja PEMFC-a na temelju mjerenja impedancije	NN	Simuliran	Predložena metoda uspijeva otkriti kvarove plavljenja i isušivanja s visokim postotkom točnosti
Shao i sur. [72], 2014.	PEMFC	Primjena metode ansambla NN za otkrivanje 4 različite vrste kvara unutar PEMFC-a	Ansambl NN	Simuliran	Predložena metoda ansambla NN uspijeva postići točnost otkrivanja kvara od 94,24%
Costamagna i sur. [73], 2019.	SOFC	Otkrivanje kvara SOFC primjenom SVM metode u slučajevima rada unutar i izvan projektiranih uvjeta	SVM	Eksperimentalan	Primijenjena SVM metoda postiže točnost otkrivanja kvara SOFC-a u rasponu od 85 do 94%, čak i kada radni uvjeti odstupaju od projektirane točke

Tablica 5.1. Sažetak pregledanih radova o primjeni strojnog učenja u otkrivanju kvarova vodikovih tehnologija (nastavak)

Autor, God	Sustav	Opis	Metoda	Skup podataka	Rezultati
Li et al. [74], 2016.	PEMFC	Otkrivanje kvara PEMFC primjenom SVM metode u slučaju implementacije uređaja u FCEV	SVM	Eksperimentalan	SVM metoda uspijeva detektirati kvarove s točnošću od 94%
Gu et al. [75], 2021.	PEMFC	Primjena LSTM modela na otkrivanje kvarova PEMFC na temelju sekvencijskih vremenskih podataka	LSTM	Eksperimentalan	Ispitivanje FCEV sustava od 92 kW pokazalo je da ovaj model može učinkovito dijagnosticirati preplavljenost gorivnih članaka te omogućiti optimizaciju vode unutar sustava u uvjetima vožnje
Zheng i sur. [76], 2017.	PEMFC	Primjena <i>Reservoir computing</i> metode za otkrivanje kvara PEMFC-a	RC	Eksperimentalan	Model uspijeva postići minimalnu stopu otkrivanja od 88% za ispitivanih 5 kvarova
Zhang i sur. [77], 2019.	SOFC	Primjena i usporedba različitih ML metoda za istovremeno otkrivanje kvarova SOFC	SVM, NN, SSAE	Simuliran	SSAE je postigao točnost od 89% u slučaju istovremenog otkrivanja više kvarova, nadmašivši NN s točnošću od 87% i SVM s točnošću od 62%

6. RASPRAVA I KRITIČKI OSVRT NA DOSADAŠNJA ISTRAŽIVANJA

6.1. Usporedba i sposobnosti ML metoda

U ovom dijelu provedena je kritička analiza i usporedba primjene ML metoda u području vodikovih tehnologija na temelju pregledanih istraživanja predstavljenih u prethodnim poglavljima. Uzimajući u obzir činjenicu da svi radni procesi unutar gorivnih članaka i elektrolizatora još nisu u potpunosti shvaćeni, standardni pristupi temeljeni na fizikalnim modelima, koji zahtijevaju točne jednadžbe za opisivanje ponašanja tih sustava, imaju ograničenu upotrebu. Stoga su ML metode pronašle svoje mjesto u svim područjima vodikovih tehnologija, od predviđanja radnih parametar [57] i degradacije [68], pa do otkrivanja različitih kvarova [77]. Također, ove metode mogu rukovati višestrukim brojem varijabli, što ih čini izvrsnim alatom za modeliranje i predviđanje ponašanja složenih sustava poput gorivnih članaka i elektrolizatora. ML metode korištene u navedenim istraživanjima mogu se podijeliti u dvije glavne kategorije: tradicionalne ML metode i DL metode, a glavna razlika u njihovim primjenama je količina podataka potrebnih za njihovo treniranje i predviđanje rezultata.

Tradicionalne ML metode trebaju manje podataka od DL metoda, ali ti podaci obično zahtijevaju stručna znanja iz domene problema za uspješnu validaciju i obradu podataka prije treniranja modela. Obrada podataka i odabir parametara sustava za izgradnju su faze koje zahtijevaju najviše vremena. Kako bi se osiguralo da model točno opisuje unutarnje ovisnosti među različitim parametrima i daje pouzdana predviđanja, stručnjak sa znanjem iz domene problema mora pažljivo procijeniti parametre skupa podataka i odrediti koji su bitni za treniranje modela [73].

S druge strane, DL metode, koje također imaju koristi od kvalitetnih skupova podataka, zbog svojih povećanih sposobnosti u usporedbi s tradicionalnim ML metodama, mogu koristiti skupove podataka koji nisu potpuno prilagođeni specifičnom problemu kako bi proizveli točne rezultate. Na primjer, u literaturi je SAE algoritam korišten za predviđanja čak i na skupu podataka s nepotpunim podacima, te je uspio postići veliku točnost predviđanja [76]. Abiola i sur. [78] koristili su *Deep Reinforcement Learning* (DRL) za izdvajanje utjecajnih parametara na predviđanja, a koji su dalje korišteni za treniranje LSTM modela koji je uspio uhvatiti dugoročne i kratkoročne ovisnosti ulaznih parametara tijekom vremena, čime je omogućeno bolje modeliranje sustava. Međutim, ove sposobnosti predviđanja dolaze s izazovom interpretabilnosti. Jednostavnije ML metode poput stabala odluke su eksplicitne i iz njih se izravno može vidjeti kako je model došao do određenih predviđanja, dok DL metode rade na mehanizmu koji još uvijek nije u potpunosti shvaćen i nazivaju se tzv. "crnim kutijama". Ova netransparentnost predstavlja veliki izazov, posebno u vodikovim tehnologijama gdje je razumijevanje ponašanja sustava ključno. Dok maksimiziranje preciznosti predviđanja može unaprijediti vodikove tehnologije, žrtvovanje interpretabilnosti može smanjiti povjerenje i otežati prihvaćanje rezultata, posebno u području otkrivanja kvarova gdje pogrešna predviđanja mogu dovesti do velikih troškova. Osim toga, potrebno je uzeti u obzir računalne zahtjeve za izgradnju ovih modela. Za velike skupove podataka i složene arhitekture obično je potreban pristup snažnom hardveru poput grafičke procesne jedinice (engl. *Graphics Processing Unit*, GPU) kako bi se iteriralo kroz fazu razvoja modela [63]. Za istraživačke potrebe, prosječno prijenosno računalo zadovoljava računalne zahtjeve [67], ali za industrijske potrebe, gdje je potrebno puno iteracija, to može predstavljati značajan dodatni trošak.

6.2. Izazovi u vezi s podacima i generalizacijom

ML metode pokazale su se kao izvrsno sredstvo za značajno smanjenje vremena potrebnog za dobivanje rezultata u usporedbi s tradicionalnim metodama temeljenim na fizikalnim modelima, ali često se suočavaju s problemom generalizacije. Jedan od načina za poboljšanje generalizacije ovih modela je treniranje na većem broju podataka. Skupovi podataka korišteni za razvoj modela generiraju se izvođenjem eksperimenata u laboratoriju, izvođenjem simulacija na računalima, ili kombinacijom oba pristupa. Laboratorijski eksperimenti obično su skupi, ograničeni eksperimentalnim postavkama, ali generiraju točna mjerenja iz stvarnog svijeta. Simulacije su obično jeftinije od eksperimenata i pružaju veću fleksibilnost, ali zahtijevaju mnogo računalne snage za generiranje rezultata i nisu toliko točne. ML metode, kako bi pružile točna predviđanja, moraju biti trenirane na kvalitetnim podacima i rade na principu da što su trenirane na više podataka, to bolje funkcioniraju. Nepostojanje velikih skupova podataka obično je ono što ograničava primjenu ML metoda na specifične slučajeve. Ovaj problem mogao bi se riješiti standardizacijom metoda prikupljanja podataka, što bi omogućilo istraživačima da kombiniraju rezultate simulacija ili eksperimenata drugih istraživača i izgrade veće skupove podataka. Također, odabir ulaznih parametara zahtijeva specifična znanja iz domene problema i ručni odabir istih. Međutim, ML metode, osim u predviđanju, mogu pomoći i u odabiru utjecajnih parametara, kao što je prikazano u radovima Huo i sur. [55], te Abiola i sur. [78].

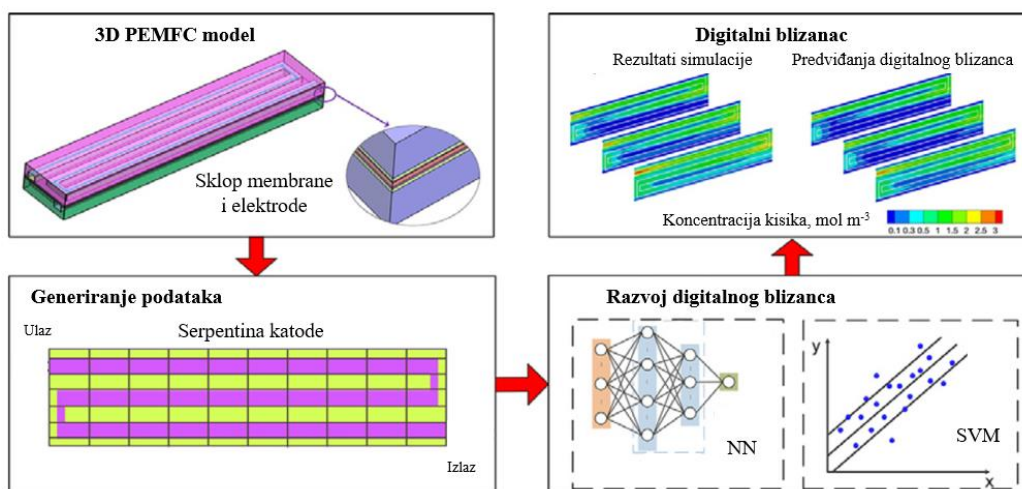
Još jedan način za poboljšanje generalizacije je kroz unaprjeđenje arhitekture različitih ML modela. Implementacija metoda regularizacije poput *Batch normalization* ili *Dropout layer* može omogućiti treniranje složenijih modela smanjujući vjerojatnost *overfitting*-a na malom skupu podataka [68]. Na manjim skupovima podataka, unakrsna validacija također poboljšava generalizaciju modela jer validira model na cjelokupnom skupu podataka [53]. S druge strane, tzv. transferno učenje može omogućiti podešavanje modela koji su razvijeni za slične zadatke, ali pod različitim uvjetima, kako bi se uštedjelo vrijeme treniranja i treniralo na više podataka [69]. Nadalje, kako bi modeli točnije predviđali fizikalne procese unutar modeliranog sustava, dizajn funkcija gubitka, koje uzimaju u obzir poznate fizikalne jednadžbe za izračun gubitaka, se može implementirati za vrijeme treniranja modela [79]. U konačnici, primjena svih ovih metoda može poboljšati generalizaciju, a posljedično robusnost i sposobnost učenja iz manjih količina podataka.

6.3. Digitalni blizanci kao budućnost primjene ML metoda

Načelno, napredniji modeli mogu postići veliku točnost, što je istaknuto u mnogim radovima. Međutim, radovi se obično fokusiraju na jedan specifičan problem gdje se pokazuje da napredni modeli nisu najbolji izbor jer jednostavne ML metode mogu lako postići niže, ali zadovoljavajuće rezultate točnosti s mnogo većom interpretabilnošću i manjom računalnom složenošću. Naravno, to ne znači da ne trebamo naprednije modele, nego baš suprotno. Gotovo svi autori naglašavaju da je za praktičnu implementaciju ML metoda potrebno ispitati više parametara pod različitim radnim uvjetima kako bi se omogućilo točnije modeliranje sustava. U tom slučaju, kada su dostupni veći skupovi podataka koji pokrivaju cijeli radni raspon parametara sustava, napredna optimizacija i predviđanja na razini uređaja postaju moguće korištenjem DL metoda.

Sposobnost DL metoda da predviđaju složene probleme omogućava stvaranje digitalnih blizanaca sustava, što omogućuje izvođenje više eksperimenata i unaprjeđenje istraživanja ovih sustava. Točni digitalni blizanci mogu značajno smanjiti troškove optimizacije, koja je često ograničena

vremenom i troškovima potrebnim za izvođenje više eksperimenata i simulacija. Također, pouzdani digitalni blizanci nam mogu omogućiti bolji uvid u mehanizme rada vodikovih tehnologija koji još nisu u potpunosti shvaćeni. Jedan od primjera primjene surogatnog modeliranja u vodikovim tehnologijama predstavljen je u radu Wang i sur. [80], gdje je surogatni model PEMFC-a korišten za optimizaciju sastava katalitičkog sloja. Optimizacija je postignuta kombiniranjem SVM-a za surogatno modeliranje i GA algoritma za optimizaciju katalitičkog sloja. SVM model postigao je vrijednost kvadratnog koeficijenta korelacije od 0,9908. Fizikalni CFD model pokrenut je s optimiranim postavkama za provjeru predviđanja, rezultirajući samo s 1,395% razlike između rezultata surogatnog modela i CFD modela, dok je postignuto unaprjeđenje računalne učinkovitosti od 10000 puta. Također, u svom drugom radu, Wang i sur. [81] predstavili su istraživanje u kojem su SVM i NN implementirani za stvaranje digitalnog blizanca PEMFC-a koji predviđa odnose različitih fizikalnih mehanizama. Ilustracija razvoja digitalnog blizanca PEMFC-a prikazana je na slici 6.1. Konkretno, autori su u ovom radu razvili digitalnog blizanca na temelju skupa podataka s mjerenjima tijekom aktivacijskog procesa unutar PEMFC-a, prikazujući interakciju između sloja za difuziju plina, mikro-poroznog sloja i katalitičkih slojeva anode i katode, te membrane. Ponovno su pokazali da digitalni bliznac ima usporedivu točnost za predviđanje odnosa različitih fizikalnih mehanizama s onom sveobuhvatnog 3D fizikalnog modela, dok je računalna učinkovitost tisućama puta veća od 3D fizikalnog modela.



Slika 6.1. Ilustracija razvoja digitalnog blizanca PEMFC-a, prilagođeno iz [81]

Osim optimizacije, digitalni blizanci mogu poboljšati praćenje i dijagnostiku vodikovih sustava. Wu i sur. [82] predstavili su primjenu NN modela za optimizaciju i dizajn strategije prilagodljivog upravljanja u stvarnom vremenu. Model je uspio postići kvadratni koeficijent korelacije od 0,9243 i omogućio dizajn strategije prilagodljivog upravljanja u stvarnom vremenu, što je rezultiralo smanjenjem vremena pokretanja hladnog PEMFC-a za 26,7%, na početnoj temperaturi od 20 °C.

Abiola i sur. u svom su radu koristili DRL u kombinaciji s LSTM modelom kako bi izgradili model za prediktivno održavanje koje može poboljšati praćenje PEMWE-a, čak i ako senzori postanu neispravni. Postignuta je velika točnost s RMSE od 0,1351 između eksperimentalnih mjerenja senzora i predviđenih vrijednosti, što ponovno pokazuje potencijal primjene surogatnih modela u optimizaciji sustava, osnažujući dijagnostiku i praćenje s manjom invazivnošću na sustav, te smanjujući potrebu za skupom opremom.

7. ZAKLJUČAK

U ovom radu istražena su područja primjene metoda strojnog učenja za predviđanje radnih parametara, degradacije i otkrivanja kvarova u vodikovih tehnologijama, te je provedena kritička analiza dosadašnjih znanstvenih spoznaja i ograničenja. Pregled literature pokazao je da DL metode općenito nadmašuju tradicionalne ML metode zbog svojih složenijih i naprednijih arhitektura. Također, za obje podskupine metoda su poželjni veći skupovi podataka visoke kvalitete, ali tradicionalne metode ML su učinkovitije s manjim količinama kvalitetnih podataka, a i manje su računalno zahtjevne. S druge strane, metode DL mogu rukovati nedosljednostima u podacima te, kako skupovi podataka postaju veći, obično nadmašuju tradicionalne metode. Međutim, problem s DL metodama je što njihove napredne sposobnosti predviđanja dolaze s nedostatkom interpretabilnosti, jer mehanizam rada ovih algoritama trenutno nije u potpunosti shvaćen i često se naziva sustavom tzv. crne kutije. Trenutno, kada se primjenjuju ove metode, kompromis između točnosti i interpretabilnosti nešto je o čemu treba pažljivo razmisliti u početnoj fazi istraživanja, ovisno o krajnjem cilju. Kod modeliranja jednostavnijih slučajeva, složeniji modeli mogu često *overfit*-ati podatke na kojima su trenirani, što ih čini beskorisnima kada se primjenjuju na različite skupove podataka. Za ove scenarije, opća preporuka je korištenje tehnika regularizacije, poput normalizacije i *Dropout layer*-a, te poboljšanje funkcija gubitka integracijom fizikalnih jednadžbi koje osiguravaju da je model temeljen na fizici ovih sustava. Za validaciju ovih modela, budući da su uglavnom trenirani na manjim skupovima podataka, uvijek bi trebalo koristiti unakrsnu validaciju kako bi se modelu osigurao maksimalan broj podataka za treniranje. S druge strane, za generiranje podataka bi se trebala definirati i provesti standardizacija izvođenja eksperimenata kako bi istraživači mogli surađivati i stvarati veće skupove podataka visoke kvalitete kako bi se iskoristio puni potencijal ovih metoda. Također, uočljivo je da se ove metode šire na područje digitalnih blizanaca, što omogućuje bolje razumijevanje interakcije različitih procesa unutar modeliranih sustava, te izgradnju naprednijih alata za dijagnostiku i praćenje.

Zaključno, unatoč prethodno elaboriranim izazovima u ovome području, obećavajući rezultati u različitim primjenama pokazuju da ML metode imaju potencijal revolucionirati postupke u dizajnu, optimizaciji i dijagnostici vodikovih tehnologija, te tako izravno doprinijeti unaprjeđivanju i boljem razumijevanju održivih vodikovih energetske sustava u budućnosti.

LITERATURA

- [1] K. T. Møller, T. R. Jensen, E. Akiba, i H. Li, „Hydrogen - A sustainable energy carrier“, *Prog. Nat. Sci. Mater. Int.*, sv. 27, izd. 1, str. 34–40, velj. 2017, doi: 10.1016/j.pnsc.2016.12.014.
- [2] „Europe hydrogen goals“, s Interneta, https://energy.ec.europa.eu/topics/energy-systems-integration/hydrogen_en, 03.04.2024.
- [3] S. E. Hosseini i B. Butler, „An overview of development and challenges in hydrogen powered vehicles“, *Int. J. Green Energy*, sv. 17, izd. 1, str. 13–37, sij. 2020, doi: 10.1080/15435075.2019.1685999.
- [4] A. Pérez *i ostali*, „Hydrogen production by isothermal thermochemical cycles using La_{0.8}Ca_{0.2}MeO_{3±δ} (Me = Co, Ni, Fe and Cu) perovskites“, *Int. J. Hydrog. Energy*, sv. 52, str. 1101–1112, sij. 2024, doi: 10.1016/j.ijhydene.2023.06.272.
- [5] E. Irandoost, N. S. Berekati, H. Farsi, A. Farrokhi, G. Horvath, i Z. Li, „Cobalt–organic framework as a Bi–functional electrocatalyst for renewable hydrogen production by electrochemical water splitting“, *Appl. Energy Combust. Sci.*, sv. 17, str. 100240, ožu. 2024, doi: 10.1016/j.jaecs.2023.100240.
- [6] E. B. Ekwenna, S. Tabraiz, Y. Wang, i A. Roskilly, „Exploring the feasibility of biological hydrogen production using seed sludge pretreated with agro-industrial wastes“, *Renew. Energy*, sv. 215, str. 118934, lis. 2023, doi: 10.1016/j.renene.2023.118934.
- [7] S. Xu, X. Huang, i H. Lu, „Photocatalytic reforming of biomass for hydrogen production: A comprehensive overview“, *Fuel Process. Technol.*, sv. 255, str. 108057, svi. 2024, doi: 10.1016/j.fuproc.2024.108057.
- [8] M. A. Abdelkareem *i ostali*, „Progress of artificial neural networks applications in hydrogen production“, *Chem. Eng. Res. Des.*, sv. 182, str. 66–86, lip. 2022, doi: 10.1016/j.cherd.2022.03.030.
- [9] C. Likkasit, A. Maroufmashat, A. Elkamel, H. Ku, i M. Fowler, „Solar-aided hydrogen production methods for the integration of renewable energies into oil & gas industries“, *Energy Convers. Manag.*, sv. 168, str. 395–406, srp. 2018, doi: 10.1016/j.enconman.2018.04.057.
- [10] F. N. Khatib *i ostali*, „Material degradation of components in polymer electrolyte membrane (PEM) electrolytic cell and mitigation mechanisms: A review“, *Renew. Sustain. Energy Rev.*, sv. 111, str. 1–14, ruj. 2019, doi: 10.1016/j.rser.2019.05.007.
- [11] P. Shirvanian i F. Van Berkel, „Novel components in Proton Exchange Membrane (PEM) Water Electrolyzers (PEMWE): Status, challenges and future needs. A mini review“, *Electrochem. Commun.*, sv. 114, str. 106704, svi. 2020, doi: 10.1016/j.elecom.2020.106704.
- [12] H. Ito, T. Maeda, A. Nakano, A. Kato, i T. Yoshida, „Influence of pore structural properties of current collectors on the performance of proton exchange membrane electrolyzer“, *Electrochimica Acta*, sv. 100, str. 242–248, lip. 2013, doi: 10.1016/j.electacta.2012.05.068.
- [13] W. Ming *i ostali*, „A systematic review of machine learning methods applied to fuel cells in performance evaluation, durability prediction, and application monitoring“, *Int. J. Hydrog. Energy*, sv. 48, izd. 13, str. 5197–5228, velj. 2023, doi: 10.1016/j.ijhydene.2022.10.261.
- [14] Y. Wang, B. Seo, B. Wang, N. Zamel, K. Jiao, i X. C. Adroher, „Fundamentals, materials, and machine learning of polymer electrolyte membrane fuel cell technology“, *Energy AI*, sv. 1, str. 100014, kol. 2020, doi: 10.1016/j.egyai.2020.100014.
- [15] M. Yue, H. Lambert, E. Pahon, R. Roche, S. Jemei, i D. Hissel, „Hydrogen energy systems: A critical review of technologies, applications, trends and challenges“, *Renew. Sustain. Energy Rev.*, sv. 146, str. 111180, kol. 2021, doi: 10.1016/j.rser.2021.111180.
- [16] R. Ding *i ostali*, „Machine learning utilized for the development of proton exchange membrane electrolyzers“, *J. Power Sources*, sv. 556, str. 232389, velj. 2023, doi: 10.1016/j.jpowsour.2022.232389.

- [17] A. Z. Tomić, I. Pivac, i F. Barbir, „A review of testing procedures for proton exchange membrane electrolyzer degradation“, *J. Power Sources*, sv. 557, str. 232569, velj. 2023, doi: 10.1016/j.jpowsour.2022.232569.
- [18] Z. Liu, S. Cai, Z. Tu, i S. H. Chan, „Recent development in degradation mechanisms of proton exchange membrane fuel cells for vehicle applications: problems, progress, and perspectives“, *Energy Storage Sav.*, sv. 3, izd. 2, str. 106–152, lip. 2024, doi: 10.1016/j.enss.2024.02.005.
- [19] B. Reuillard *i ostali*, „Noncovalent Integration of a Bioinspired Ni Catalyst to Graphene Acid for Reversible Electrocatalytic Hydrogen Oxidation“, *ACS Appl. Mater. Interfaces*, sv. 12, izd. 5, str. 5805–5811, velj. 2020, doi: 10.1021/acscami.9b18922.
- [20] J. Parbey, M. Xu, J. Lei, M. Espinoza-Andaluz, T. S. Li, i M. Andersson, „Electrospun fabrication of nanofibers as high-performance cathodes of solid oxide fuel cells“, *Ceram. Int.*, sv. 46, izd. 5, str. 6969–6972, tra. 2020, doi: 10.1016/j.ceramint.2019.11.099.
- [21] M. Laimon i T. Yusaf, „Towards energy freedom: Exploring sustainable solutions for energy independence and self-sufficiency using integrated renewable energy-driven hydrogen system“, *Renew. Energy*, sv. 222, str. 119948, velj. 2024, doi: 10.1016/j.renene.2024.119948.
- [22] Q. V. Dinh, P. H. T. Pereira, V. N. Dinh, A. J. Nagle, i P. G. Leahy, „Levelised cost of transmission comparison for green hydrogen and ammonia in new-build offshore energy infrastructure: Pipelines, tankers, and HVDC“, *Int. J. Hydrog. Energy*, sv. 62, str. 684–698, tra. 2024, doi: 10.1016/j.ijhydene.2024.03.066.
- [23] M. A. Green, „Hydrogen Safety Issues Compared to Safety Issues with Methane and Propane“, u *AIP Conference Proceedings*, Keystone, Colorado (USA): AIP, 2006, str. 319–326. doi: 10.1063/1.2202431.
- [24] H. Li *i ostali*, „Safety of hydrogen storage and transportation: An overview on mechanisms, techniques, and challenges“, *Energy Rep.*, sv. 8, str. 6258–6269, stu. 2022, doi: 10.1016/j.egyr.2022.04.067.
- [25] R. R. Ratnakar *i ostali*, „Hydrogen supply chain and challenges in large-scale LH2 storage and transportation“, *Int. J. Hydrog. Energy*, sv. 46, izd. 47, str. 24149–24168, srp. 2021, doi: 10.1016/j.ijhydene.2021.05.025.
- [26] D. Nill, „Studie zum Rechtsrahmen einer zukünftigen Wasserstoffwirtschaft“.
- [27] S. Lipiäinen, K. Lipiäinen, A. Ahola, i E. Vakkilainen, „Use of existing gas infrastructure in European hydrogen economy“, *Int. J. Hydrog. Energy*, sv. 48, izd. 80, str. 31317–31329, ruj. 2023, doi: 10.1016/j.ijhydene.2023.04.283.
- [28] P. Adam i F. Heunemann, „Hydrogen infrastructure – the pillar of energy transition“, 2020.
- [29] „FNB (2020)“, sa Interneta, https://fnb-gas.de/wp-content/uploads/2021/09/towards_a_competitive_hydrogen_market_april_2020_en-1.pdf, 05.04.2024.
- [30] M. Wietschel *i ostali*, „Opportunities and challenges when importing green hydrogen and synthesis products“.
- [31] A. Sai Ramesh *i ostali*, „Artificial intelligence driven hydrogen and battery technologies – A review“, *Fuel*, sv. 337, str. 126862, tra. 2023, doi: 10.1016/j.fuel.2022.126862.
- [32] R. Ding *i ostali*, „Applying machine learning to boost the development of high-performance membrane electrode assembly for proton exchange membrane fuel cells“, *J. Mater. Chem. A*, sv. 9, izd. 11, str. 6841–6850, 2021, doi: 10.1039/D0TA12571G.
- [33] R. Ding *i ostali*, „Machine Learning-Guided Discovery of Underlying Decisive Factors and New Mechanisms for the Design of Nonprecious Metal Electrocatalysts“, *ACS Catal.*, sv. 11, izd. 15, str. 9798–9808, kol. 2021, doi: 10.1021/acscatal.1c01473.
- [34] M. Mehrpooya, B. Ghorbani, B. Jafari, M. Aghbashlo, i M. Pouriman, „Modeling of a single cell micro proton exchange membrane fuel cell by a new hybrid neural network method“, *Therm. Sci. Eng. Prog.*, sv. 7, str. 8–19, ruj. 2018, doi: 10.1016/j.tsep.2018.04.012.
- [35] H. Hwang *i ostali*, „Integrated application of semantic segmentation-assisted deep learning to quantitative multi-phased microstructural analysis in composite materials: Case study of cathode

- composite materials of solid oxide fuel cells“, *J. Power Sources*, sv. 471, str. 228458, ruj. 2020, doi: 10.1016/j.jpowsour.2020.228458.
- [36] K. T. P. Nguyen i K. Medjaher, „A new dynamic predictive maintenance framework using deep learning for failure prognostics“, *Reliab. Eng. Syst. Saf.*, sv. 188, str. 251–262, kol. 2019, doi: 10.1016/j.ress.2019.03.018.
- [37] A. Al-Othman *i ostali*, „Artificial intelligence and numerical models in hybrid renewable energy systems with fuel cells: Advances and prospects“, *Energy Convers. Manag.*, sv. 253, str. 115154, velj. 2022, doi: 10.1016/j.enconman.2021.115154.
- [38] G. Bilgiç, E. Bendeş, B. Öztürk, i S. Atasever, „Recent advances in artificial neural network research for modeling hydrogen production processes“, *Int. J. Hydrog. Energy*, sv. 48, izd. 50, str. 18947–18977, lip. 2023, doi: 10.1016/j.ijhydene.2023.02.002.
- [39] G. Napoli, M. Ferraro, F. Sergi, G. Brunaccini, i V. Antonucci, „Data driven models for a PEM fuel cell stack performance prediction“, *Int. J. Hydrog. Energy*, sv. 38, izd. 26, str. 11628–11638, kol. 2013, doi: 10.1016/j.ijhydene.2013.04.135.
- [40] A. U. Chávez-Ramírez *i ostali*, „High power fuel cell simulator based on artificial neural network“, *Int. J. Hydrog. Energy*, sv. 35, izd. 21, str. 12125–12133, stu. 2010, doi: 10.1016/j.ijhydene.2009.09.071.
- [41] Y. Bicer, I. Dincer, i M. Aydin, „Maximizing performance of fuel cell using artificial neural network approach for smart grid applications“, *Energy*, sv. 116, str. 1205–1217, pros. 2016, doi: 10.1016/j.energy.2016.10.050.
- [42] J. Milewski i K. Świrski, „Modelling the SOFC behaviours by artificial neural network“, *Int. J. Hydrog. Energy*, sv. 34, izd. 13, str. 5546–5553, srp. 2009, doi: 10.1016/j.ijhydene.2009.04.068.
- [43] O. Razbani i M. Assadi, „Artificial neural network model of a short stack solid oxide fuel cell based on experimental data“, *J. Power Sources*, sv. 246, str. 581–586, sij. 2014, doi: 10.1016/j.jpowsour.2013.08.018.
- [44] O. Razbani, M. Assadi, i M. Andersson, „Three dimensional CFD modeling and experimental validation of an electrolyte supported solid oxide fuel cell fed with methane-free biogas“, *Int. J. Hydrog. Energy*, sv. 38, izd. 24, str. 10068–10080, kol. 2013, doi: 10.1016/j.ijhydene.2013.05.153.
- [45] Y. Sewsynker, E. B. G. Kana, i A. Lateef, „Modelling of biohydrogen generation in microbial electrolysis cells (MECs) using a committee of artificial neural networks (ANNs)“, *Biotechnol. Biotechnol. Equip.*, sv. 29, izd. 6, str. 1208–1215, stu. 2015, doi: 10.1080/13102818.2015.1062732.
- [46] A. Garg, V. Vijayaraghavan, S. S. Mahapatra, K. Tai, i C. H. Wong, „Performance evaluation of microbial fuel cell by artificial intelligence methods“, *Expert Syst. Appl.*, sv. 41, izd. 4, str. 1389–1399, ožu. 2014, doi: 10.1016/j.eswa.2013.08.038.
- [47] E. Entchev i L. Yang, „Application of adaptive neuro-fuzzy inference system techniques and artificial neural networks to predict solid oxide fuel cell performance in residential microgeneration installation“, *J. Power Sources*, sv. 170, izd. 1, str. 122–129, lip. 2007, doi: 10.1016/j.jpowsour.2007.04.015.
- [48] Y. Özçelep, S. Sevgen, i R. Samli, „A study on the hydrogen consumption calculation of proton exchange membrane fuel cells for linearly increasing loads: Artificial Neural Networks vs Multiple Linear Regression“, *Renew. Energy*, sv. 156, str. 570–578, kol. 2020, doi: 10.1016/j.renene.2020.04.085.
- [49] T. Wilberforce i A. G. Olabi, „Proton exchange membrane fuel cell performance prediction using artificial neural network“, *Int. J. Hydrog. Energy*, sv. 46, izd. 8, str. 6037–6050, sij. 2021, doi: 10.1016/j.ijhydene.2020.07.263.
- [50] M. Seyhan, Y. E. Akansu, M. Murat, Y. Korkmaz, i S. O. Akansu, „Performance prediction of PEM fuel cell with wavy serpentine flow channel by using artificial neural network“, *Int. J. Hydrog. Energy*, sv. 42, izd. 40, str. 25619–25629, lis. 2017, doi: 10.1016/j.ijhydene.2017.04.001.
- [51] N. Khajeh-Hosseini-Dalasm, S. Ahadian, K. Fushinobu, K. Okazaki, i Y. Kawazoe, „Prediction and analysis of the cathode catalyst layer performance of proton exchange membrane fuel cells using

- artificial neural network and statistical methods“, *J. Power Sources*, sv. 196, izd. 8, str. 3750–3756, tra. 2011, doi: 10.1016/j.jpowsour.2010.12.061.
- [52] F. Z. Arama, K. Mammam, S. Laribi, A. Necaibia, i T. Ghaitaoui, „Implementation of sensor based on neural networks technique to predict the PEM fuel cell hydration state“, *J. Energy Storage*, sv. 27, str. 101051, velj. 2020, doi: 10.1016/j.est.2019.101051.
- [53] I.-S. Han i C.-B. Chung, „Performance prediction and analysis of a PEM fuel cell operating on pure oxygen using data-driven models: A comparison of artificial neural network and support vector machine“, *Int. J. Hydrog. Energy*, sv. 41, izd. 24, str. 10202–10211, lip. 2016, doi: 10.1016/j.ijhydene.2016.04.247.
- [54] C. Guo, J. Lu, Z. Tian, W. Guo, i A. Darvishan, „Optimization of critical parameters of PEM fuel cell using TLBO-DE based on Elman neural network“, *Energy Convers. Manag.*, sv. 183, str. 149–158, ožu. 2019, doi: 10.1016/j.enconman.2018.12.088.
- [55] W. Huo, W. Li, Z. Zhang, C. Sun, F. Zhou, i G. Gong, „Performance prediction of proton-exchange membrane fuel cell based on convolutional neural network and random forest feature selection“, *Energy Convers. Manag.*, sv. 243, str. 114367, ruj. 2021, doi: 10.1016/j.enconman.2021.114367.
- [56] J. Xie, H. Yuan, Y. Wu, C. Wang, X. Wei, i H. Dai, „Impedance Acquisition of Proton Exchange Membrane Fuel Cell Using Deeper Learning Network“, *Energies*, sv. 16, izd. 14, str. 5556, srp. 2023, doi: 10.3390/en16145556.
- [57] J. Paciocco, T. Cawte, i A. Bazylak, „Predicting optimal membrane hydration and ohmic losses in operating fuel cells with machine learning“, *J. Power Sources*, sv. 573, str. 233119, srp. 2023, doi: 10.1016/j.jpowsour.2023.233119.
- [58] Colliard-Granero, „Deep Learning-Enhanced Characterization of Bubble Dynamics in Proton Exchange Membrane Water Electrolyzers“, doi: 10.1039/D3CP05869G.
- [59] M. Bahr, A. Gusak, S. Stypka, i B. Oberschachtsiek, „Artificial Neural Networks for Aging Simulation of Electrolysis Stacks“, *Chem. Ing. Tech.*, sv. 92, izd. 10, str. 1610–1617, lis. 2020, doi: 10.1002/cite.202000089.
- [60] A. Hayatzadeh, M. Fattahi, i A. Rezaveisi, „Machine learning algorithms for operating parameters predictions in proton exchange membrane water electrolyzers: Anode side catalyst“, *Int. J. Hydrog. Energy*, sv. 56, str. 302–314, velj. 2024, doi: 10.1016/j.ijhydene.2023.12.149.
- [61] S. Morando, S. Jemei, D. Hissel, R. Gouriveau, i N. Zerhouni, „Proton exchange membrane fuel cell ageing forecasting algorithm based on Echo State Network“, *Int. J. Hydrog. Energy*, sv. 42, izd. 2, str. 1472–1480, sij. 2017, doi: 10.1016/j.ijhydene.2016.05.286.
- [62] Y. Cheng, N. Zerhouni, i C. Lu, „A hybrid remaining useful life prognostic method for proton exchange membrane fuel cell“, *Int. J. Hydrog. Energy*, sv. 43, izd. 27, str. 12314–12327, srp. 2018, doi: 10.1016/j.ijhydene.2018.04.160.
- [63] L. Vichard, F. Harel, A. Ravey, P. Venet, i D. Hissel, „Degradation prediction of PEM fuel cell based on artificial intelligence“, *Int. J. Hydrog. Energy*, sv. 45, izd. 29, str. 14953–14963, svi. 2020, doi: 10.1016/j.ijhydene.2020.03.209.
- [64] K. Chen, S. Laghrouche, i A. Djerdir, „Degradation prediction of proton exchange membrane fuel cell based on grey neural network model and particle swarm optimization“, *Energy Convers. Manag.*, sv. 195, str. 810–818, ruj. 2019, doi: 10.1016/j.enconman.2019.05.045.
- [65] R. Ma, E. Breaz, C. Liu, H. Bai, P. Briois, i F. Gao, „Data-driven Prognostics for PEM Fuel Cell Degradation by Long Short-term Memory Network“, u *2018 IEEE Transportation Electrification Conference and Expo (ITEC)*, Long Beach, CA, USA: IEEE, lip. 2018, str. 102–107. doi: 10.1109/ITEC.2018.8449962.
- [66] J. Zuo i ostali, „Deep learning based prognostic framework towards proton exchange membrane fuel cell for automotive application“, *Appl. Energy*, sv. 281, str. 115937, sij. 2021, doi: 10.1016/j.apenergy.2020.115937.
- [67] J. Liu, Q. Li, W. Chen, Y. Yan, Y. Qiu, i T. Cao, „Remaining useful life prediction of PEMFC based on long short-term memory recurrent neural networks“, *Int. J. Hydrog. Energy*, sv. 44, izd. 11, str. 5470–5480, velj. 2019, doi: 10.1016/j.ijhydene.2018.10.042.

- [68] B. Zuo, J. Cheng, i Z. Zhang, „Degradation prediction model for proton exchange membrane fuel cells based on long short-term memory neural network and Savitzky-Golay filter“, *Int. J. Hydrog. Energy*, sv. 46, izd. 29, str. 15928–15937, tra. 2021, doi: 10.1016/j.ijhydene.2021.02.069.
- [69] J. Ma i ostali, „Degradation prognosis for proton exchange membrane fuel cell based on hybrid transfer learning and intercell differences“, *ISA Trans.*, sv. 113, str. 149–165, srp. 2021, doi: 10.1016/j.isatra.2020.06.005.
- [70] T. Xue i ostali, „Fault Diagnosis of SOFC Stack Based on Neural Network Algorithm“, *Energy Procedia*, sv. 158, str. 1798–1803, velj. 2019, doi: 10.1016/j.egypro.2019.01.423.
- [71] S. Laribi, K. Mammam, Y. Sahli, i K. Koussa, „Analysis and diagnosis of PEM fuel cell failure modes (flooding & drying) across the physical parameters of electrochemical impedance model: Using neural networks method“, *Sustain. Energy Technol. Assess.*, sv. 34, str. 35–42, kol. 2019, doi: 10.1016/j.seta.2019.04.004.
- [72] M. Shao, X.-J. Zhu, H.-F. Cao, i H.-F. Shen, „An artificial neural network ensemble method for fault diagnosis of proton exchange membrane fuel cell system“, *Energy*, sv. 67, str. 268–275, tra. 2014, doi: 10.1016/j.energy.2014.01.079.
- [73] P. Costamagna, A. De Giorgi, G. Moser, L. Pellaco, i A. Trucco, „Data-driven fault diagnosis in SOFC-based power plants under off-design operating conditions“, *Int. J. Hydrog. Energy*, sv. 44, izd. 54, str. 29002–29006, stu. 2019, doi: 10.1016/j.ijhydene.2019.09.128.
- [74] Z. Li i ostali, „Online implementation of SVM based fault diagnosis strategy for PEMFC systems“, *Appl. Energy*, sv. 164, str. 284–293, velj. 2016, doi: 10.1016/j.apenergy.2015.11.060.
- [75] X. Gu, Z. Hou, i J. Cai, „Data-based flooding fault diagnosis of proton exchange membrane fuel cell systems using LSTM networks“, *Energy AI*, sv. 4, str. 100056, lip. 2021, doi: 10.1016/j.egyai.2021.100056.
- [76] Z. Zheng i ostali, „Brain-inspired computational paradigm dedicated to fault diagnosis of PEM fuel cell stack“, *Int. J. Hydrog. Energy*, sv. 42, izd. 8, str. 5410–5425, velj. 2017, doi: 10.1016/j.ijhydene.2016.11.043.
- [77] Z. Zhang, S. Li, Y. Xiao, i Y. Yang, „Intelligent simultaneous fault diagnosis for solid oxide fuel cell system based on deep learning“, *Appl. Energy*, sv. 233–234, str. 930–942, sij. 2019, doi: 10.1016/j.apenergy.2018.10.113.
- [78] A. Abiola, F. S. Manzano, i J. M. Andújar, „A Novel Deep Reinforcement Learning (DRL) Algorithm to Apply Artificial Intelligence-Based Maintenance in Electrolysers“, *Algorithms*, sv. 16, izd. 12, str. 541, stu. 2023, doi: 10.3390/a16120541.
- [79] S. Wang, S. Sankaran, H. Wang, i P. Perdikaris, „An Expert’s Guide to Training Physics-informed Neural Networks“, s Interneta, <http://arxiv.org/abs/2308.08468>, 06.04.2024.
- [80] B. Wang, B. Xie, J. Xuan, i K. Jiao, „AI-based optimization of PEM fuel cell catalyst layers for maximum power density via data-driven surrogate modeling“, *Energy Convers. Manag.*, sv. 205, str. 112460, velj. 2020, doi: 10.1016/j.enconman.2019.112460.
- [81] B. Wang, G. Zhang, H. Wang, J. Xuan, i K. Jiao, „Multi-physics-resolved digital twin of proton exchange membrane fuel cells with a data-driven surrogate model“, *Energy AI*, sv. 1, str. 100004, kol. 2020, doi: 10.1016/j.egyai.2020.100004.
- [82] K. Wu i ostali, „Enabling real-time optimization of dynamic processes of proton exchange membrane fuel cell: Data-driven approach with semi-recurrent sliding window method“, *Appl. Energy*, sv. 303, str. 117659, pros. 2021, doi: 10.1016/j.apenergy.2021.117659.

POPIS OZNAKA I KRATICA

AE	Alkaline Electrolyzer	alkalijski elektrolizator
AEM	Anion Exchange Membrane	alkalno-membranskih elektrolizatora
AFC	Alkaline Fuel Cell	alkalijski gorivni članak
ANFIS	Adaptive Neuro Fuzzy Inference System	/
ANOM	Analysis of Means	/
ANOVA	Analysis of Variance	/
CFD	Computational Fluid Dynamics	računalna dinamika fluida
CL	Catalyst Layer	katalitički sloj
CNN	Convolutional Neural Network	konvolucijska neuronska mreža
CPE	Constant Phase Element	/
DE	Differential Evolution	/
DL	Deep Learning	duboko učenje
DLR	Deep Reinforcement Learning	duboko podržano učenje
DNN	Deep Neural Networks	duboka neuronska mreža
ESN	Echo State Network	/
FCEV	Fuel Cell Electric Vehicle	električna vozila s gorivnim člancima
FFBP	Feed Forward Back Propagation	/
GA	Genetic Algorithm	genetski algoritam
GMDH	Group Method of Data Handling	/
GPU	Graphics Processing Unit	grafička procesna jedinica
GRU	Gated Recurrent Unit	/
HFR	High-Frequency Impedance Resistance	/
ICE	Internal Combustion Engine	motor s unutarnjim izgaranjem
KNN	K Nearest Neighbor	/
LFR	Low-Frequency Impedance Resistance	/
LSSVM	Least Square Support Vector Machine	/
LSTM	Long Short-Term Memory	/
LWSS	Locally Weighted Scatterplot Smoothing	/
MAE	Mean Absolute Error	srednja apsolutna pogreška
MAPE	Mean Absolute Percentage Error	srednja apsolutna postotna pogreška
MCFC	Molten Carbonate Fuel Cell	gorivni članak s rastopljenim karbonatom
MEC	Microbial Electrolysis Cell	mikrobni elektrolizatorski članak
MFC	Microbial Fuel Cell	mikrobni gorivni članak
MGGP	Multi-Gene Genetic Programming	/
ML	Machine Learning	strojno učenje

MLR	Multiple Linear Regression	/
MSE	Mean Squared Error	srednja kvadratna pogreška
NN	Neural Network	neuronska mreža
NRMSE	Normalized Root Mean Squared Error	normalizirana srednja kvadratna pogreška
PAFC	Phosphoric Acid Fuel Cell	gorivni članak s fosfornom kiselinom
PEMFC	Proton Exchange Membrane Fuel Cell	membranski gorivni članak
PEMWE	Proton Exchange Membrane Water Electrolyzer	membranski elektrolizator
PSO	Particle Swarm Optimization	/
RF	Random Forest	/
RMSE	Root Mean Squared Error	korijen srednje kvadratne pogreške
RPF	Regularized Particle Filter	/
RUL	Remaining Useful Lifetime	preostali vijek trajanja
SAE	Stacked Autoencoder	/
SOE	Solid Oxide Electrolyzer	elektrolizator s krutim oksidom
SOFC	Solid Oxide Fuel Cell	gorivni članak s krutim oksidom
SSAE	Stacked Sparse Autoencoder	/
SVM	Support Vector Machines	/
SVR	Support Vector Regression	/
TLBO	Teaching-Learning-Based Optimization	/

SAŽETAK

PRIMJENA METODA STROJNOG UČENJA U VODIKOVIM TEHNOLOGIJAMA

Gorivni članci i elektrolizatori, kao ključne visokoučinkovite vodikove tehnologije, u sprezi s obnovljivim izvorima energije predstavljaju vrlo izgledno rješenje za održiv i ekološki prihvatljiv energetska sustav. Međutim, visoki kapitalni troškovi, zbog ovisnosti o skupim plemenitim metalima kao što su platina i iridij, te nedovoljna razvijenost infrastrukture, sprječavaju njihovu širu primjenu. S druge strane, najveći izazovi tijekom rada ovih uređaja su pravovremeno otkrivanje kvarova i degradacija performansi. Metode strojnog učenja, zbog svoje sposobnosti učenja iz povijesnih podataka, često se koriste za rješavanje problema u kojima ne postoje eksplicitne formule za rješenje problema, pa tako sve više i u području vodikovih tehnologija. U ovom radu je analizirana dosadašnja primjena metoda strojnog učenja u područjima predviđanja radnih parametara, otkrivanja kvarova i degradacije vodikovih tehnologija, uz usporedbu izvedbi različitih metoda, te trenutnih izazova i ograničenja u njihovoj primjeni. Na kraju, dani su prijedlozi i smjernice za buduća istraživanja u ovome području.

Ključne riječi:

vodikove tehnologije, strojno učenje, duboko učenje, radni parametri, degradacija, detekcija kvarova

ABSTRACT

MACHINE LEARNING METHODS APPLICATION IN HYDROGEN TECHNOLOGIES

Fuel cells and electrolyzers, as key high-efficiency hydrogen technologies, in conjunction with renewable energy sources represent a very promising solution for a sustainable and environmentally friendly energy system. However, high capital costs, due to dependence on expensive precious metals such as platinum and iridium, and insufficient infrastructure development, prevent their wider application. On the other hand, the biggest challenges during the operation of these devices are the timely detection of faults and performance degradation. Machine learning methods, due to their ability to learn from historical data, are often used to solve problems in which there are no explicit formulas for the solution of the problem, and so increasingly in the field of hydrogen technologies. In this paper, the previous application of machine learning methods in the fields of predicting operating parameters, detecting faults and degradation of hydrogen technologies is analyzed, along with a comparison of the performance of different methods, as well as current challenges and limitations in their application. Finally, suggestions and guidelines for future research in this area are given.

Keywords:

Hydrogen technologies, Machine learning, Deep learning, Operating parameters, Degradation, Fault detection