

Primjena umjetnih neuronskih mreža za potrebe vođenja energetskih sustava s visokim udjelom obnovljivih izvora energije

Milešević, Filip

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mining, Geology and Petroleum Engineering / Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:169:738749>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom](#).

Download date / Datum preuzimanja: **2024-07-30**



Repository / Repozitorij:

[Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET
Diplomski studij naftnog rudarstva

**PRIMJENA UMJETNIH NEURONSKIH MREŽA ZA POTREBE
VOĐENJA ENERGETSKIH SUSTAVA S VISOKIM UDJELOM
OBNOVLJIVIH IZVORA ENERGIJE**

Diplomski rad

Filip Milešević

N301

Zagreb, 2021

PRIMJENA UMJETNIH NEURONSKIH MREŽA ZA POTREBE VOĐENJA ENERGETSKIH
SUSTAVA S VISOKIM UDJELOM OBNOVLJIVIH IZVORA ENERGIJE

FILIP MILEŠEVIĆ

Diplomski rad je izrađen na: Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet

Zavod za naftno-plinsko inženjerstvo i energetiku

Pierottijeva 6, 10 000 Zagreb

Sažetak

Energetske mikromreže imaju fleksibilan sastav, kompleksne mehanizme aktivnosti i veliku količinu podataka tokom rada. Stoga, zahtijevaju složenu analizu kako bi se optimirao rad i akumuliralo znanje o vođenju. Simuliran je energetska sustav od dvije tisuće kućanstava sa visokim udjelom OIE, te na temelju rezultata simulacije bilance energetskih tokova za mikromrežu, konstruirana je umjetna neuronska mreža. Za odabrane ulazne vrijednosti, zadatak mreže je prognozirati buduće vrijednosti kontrolnih varijabli te na taj način demonstrirati sposobnost vođenja, odnosno regulacije. Stvoren je generalni model koji je na temelju analize rezultata daljnje optimiziran te je naposljetku provedena analiza osjetljivosti za dva tipična parametra. Konstruirani model pokazuje sposobnost učenja i rješavanja zadanog problema sa visokim stupnjem točnosti.

Ključne riječi: umjetna inteligencija, mikromreža, konvolucijska neuronska mreža, duboko učenje, EnergyPLAN, TensorFlow, upravljanje energijom, geotermalna dizalica topline, OIE

Diplomski rad sadrži: 51 stranica, 3 tablice, 52 slike i 20 referenci.

Jezik izvornika: hrvatski

Diplomski rad pohranjen: Knjižnica Rudarsko-geološko-naftnog fakulteta,
Pierottijeva 6, Zagreb

Mentor: Dr. sc. Luka Perković, izvanredni profesor RGNF

Ocjenjivači: 1. Dr. sc. Luka Perković, izvanredni profesor RGNF
2. Dr. sc. Tomislav Kurevija, izvanredni profesor RGNF
3. Dr. sc. Daria Karasalihović Sedlar, redovita profesorica RGNF

Datum i mjesto obrane: 16.07.2021., Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu

APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR MANAGEMENT OF ENERGY
SYSTEMS WITH HIGH SHARE OF RENEWABLE ENERGY SOURCES

FILIP MILEŠEVIĆ

Thesis completed at: University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering
Department of Petroleum and Gas Engineering and Energy
Pierottijeva 6, 10 000 Zagreb

Abstract

Energy microgrids have flexible composition, complex mechanisms of activity, and a large amount of data during operation. Therefore, they require complex analysis in order to optimize operation and accumulate scheduling knowledge. Energy system of two thousand households with a high share of RES was simulated, and based on the results of the simulation of the energy flow balance for the microgrid, an artificial neural network was constructed. For the selected input values, the task of the network is to forecast the future values of control variables and thus demonstrate the ability to control and regulate the microgrid. A general model was created, which was further optimized based on the analysis of the results, and finally a sensitivity analysis was performed for two typical parameters. The constructed model shows the ability to learn and solve a given problem with high degree of accuracy.

Keywords: AI, ANN, microgrid, convolutional neural network, deep learning, EnergyPLAN, TensorFlow, energy management, geothermal heat pump, RES

Thesis contains: 51 pages, 3 tables, 52 figures and 20 references.

Original in: Croatian

Archived at: The Library of Faculty of Mining, Geology and Petroleum Engineering,
Pierottijeva 6, Zagreb

Supervisor: Associate Professor Luka Perković, PhD

Reviewers: 1. Associate Professor Luka Perković, PhD
2. Associate Professor Tomislav Kurevija, PhD
3. Full Professor Daria Karasalihović Sedlar, PhD

Date and place of defense: 16.07.2021., Faculty of Mining, Geology and Petroleum Engineering,
University of Zagreb

SADRŽAJ

I. POPIS SLIKA.....	I
II. POPIS TABLICA.....	III
III. POPIS KORIŠTENIH OZNAKA I PRIPADAJUĆIH SI JEDINICA.....	IV
1. UVOD	1
1.1. STANJE OBNOVLJIVIH IZVORA ENERGIJE U EU.....	1
1.2. STANJE OBNOVLJIVIH IZVORA ENERGIJE U RH.....	3
1.3. KLIMATSKI I ENERGETSKI CILJEVI EU DO 2030.	6
1.4. UMJETNA NEURONSKA MREŽA - GENERALNI PRINCIP	7
1.5. KONSTRUKCIJA NEURONSKE MREŽE S OBZIROM NA KOMPLEKSNOŠĆ I TIP ULAZNIH PODATAKA	13
2. METODA	15
2.1. EnergyPLAN.....	15
2.2. UMJETNA NEURONSKA MREŽA – TENSORFLOW	17
3. ANALIZA SLUČAJA	18
3.1. POSTAVKE ANALIZE SLUČAJA ZA EnergyPLAN.....	18
3.2. POSTAVKE ANALIZE SLUČAJA – ANN.....	24
3.2.1. Manipulacija ulaznim podacima i inženjering značajki	24
3.2.2. Priprema ulaznih podataka u model	30
3.2.3. Konstrukcija modela neuronske mreže	32
3.2.3.1. <i>Temeljni model za usporedbu.....</i>	<i>32</i>
3.2.3.2. <i>Razvoj generalnog modela neuronske mreže u TensorFlow-u</i>	<i>33</i>
3.3. ANALIZA REZULTATA.....	37
3.4. ANALIZA OSJETLJIVOSTI.....	41
4. ZAKLJUČAK.....	49
5. POPIS LITERATURE.....	50

I. POPIS SLIKA

Slika 1-1.	Sveukupni udio energije iz obnovljivih izvora.....	1
Slika 1-2.	Raspodjela potrošnje energije u sektoru transformacija.....	2
Slika 1-3.	Potrošnja u odabranim sektorima po tipu energije	3
Slika 1-4.	Udjeli energije za energetske transformacije.....	4
Slika 1-5.	Proizvodnja transformiranih oblika energije	4
Slika 1-6.	Udjeli sektora u neposrednoj potrošnji energije	4
Slika 1-7.	Trend emisija CO ₂ uslijed izgaranja goriva	5
Slika 1-8.	Ciljevi EU u području ograničenja emisija do 2030.....	6
Slika 1-9.	Ciljevi EU u području OIE do 2030.	6
Slika 1-10.	Ciljevi EU u području energetske efikasnosti do 2030.	7
Slika 1-11.	Tipične aktivacijske funkcije.....	9
Slika 1-12.	Shema konvolucijskog procesa	11
Slika 1-13.	Primjer vizualizacije karte značajki korištenjem metode „dubokog sna“	11
Slika 1-14.	Struktura LSTM neuronske mreže	12
Slika 1-15.	Primjer arhitekture generativne suparničke mreže	13
Slika 2-1.	Prikaz naslovnog prozora	15
Slika 2-2.	Primjer unosa toplinske potražnje analiziranog sustava.....	16
Slika 2-3.	TensorFlow Playground – web lokacija	17
Slika 3-1.	Shema cjelokupnog modela.....	18
Slika 3-2.	Shema analiziranog energetske sustava	19
Slika 3-3.	Prikaz rezultata simulacije.....	20
Slika 3-4.	Tablični prikaz rezultata simulacije.....	22
Slika 3-5.	Jednogodišnje krivulje rezultata simulacije.....	23
Slika 3-6.	Dekompozicija vremenske serije punjenja BEV-a.....	25
Slika 3-7.	Dekompozicija vremenske serije pražnjenja BEV-a.....	25
Slika 3-8.	Fourierova transformacija krivulja	26
Slika 3-9.	Fourierova transformacija krivulje punjenja električne pohrane.....	26
Slika 3-10.	Krivulje rezultata simulacije.....	27
Slika 3-11.	Korelacijske vrijednosti simulacijskih varijabli i konstruiranih signala	28
Slika 3-12.	Korelacijske vrijednosti odabranih ulaznih varijabli.....	28

Slika 3-13.	Prikaz krivulja odabranih ulaznih varijabli za zadnji tjedan simulacije.....	29
Slika 3-14.	Prikaz krivulja odabranih ulaznih varijabli za dvije godine simulacije.....	29
Slika 3-15.	Grafovi traženih varijabli dobiveni temeljnim modelom	32
Slika 3-16.	Shema topologije konstruiranog modela	33
Slika 3-17.	Sažetak modela	34
Slika 3-18.	Primjer transformacije 2D matrice u 1D vektor	35
Slika 3-19.	Gubitci tokom treniranja.....	38
Slika 3-20.	Metrika „sličnosti kosinusa“ modela za vrijeme treniranja.....	38
Slika 3-21.	Prognoza punjenja baterije BEV-a u trajanju od jednog tjedna	39
Slika 3-22.	Prognoza punjenja toplinskog spremnika u trajanju od jednog tjedna.....	39
Slika 3-23.	Prognoza pražnjenja toplinskog spremnika u trajanju od jednog tjedna	40
Slika 3-24.	24 filtera iz prvog konvolucijskog sloja	40
Slika 3-25.	PCA dekompozicija 12 odabranih ulaznih varijabli.....	42
Slika 3-26.	Korelacija 6 značajki dobivenih PCA dekompozicijom	42
Slika 3-27.	Krivulje pet varijabli dobivenih PCA dekompozicijom	43
Slika 3-28.	Ovisnost rezultata o veličini trenažne serije	45
Slika 3-29.	Ovisnost rezultata o veličini trenažne serije	45
Slika 3-30.	Gubitci tokom treniranja.....	46
Slika 3-31.	Metrika „sličnosti kosinusa“ modela za vrijeme treniranja.....	46
Slika 3-32.	Prognoza punjenja baterije BEV-a u trajanju od jednog tjedna	47
Slika 3-33.	Prognoza punjenja toplinskog spremnika u trajanju od jednog tjedna.....	47
Slika 3-34.	Prognoza pražnjenja toplinskog spremnika u trajanju od jednog tjedna	48

II. POPIS TABLICA


Tablica 3-1. Rezultati treniranja modela	37
Tablica 3-2. Rezultati treniranja ažuriranog modela	43
Tablica 3-3. Analiza osjetljivosti modela	44

III. POPIS KORIŠTENIH OZNAKA I PRIPADAJUĆIH SI JEDINICA

OZNAKA	ZNAČENJE	SI
COP	Koeficijent efikasnosti dizalice topline	/
d_{el}	Potražnja za električnom energijom	kW
d_{th}	Potražnja za toplinskom energijom	kW
d^{BEV}_{el}	Potražnja el. vozila za električnom energijom	kW
e^{PV}_{el}	Električna energija iz solarnih panela	kW
e^W_{el}	Električna energija iz vjetroturbina	kW
$e^{V2G}_{el,in}$	Punjenje pohrane električne energije	kW
$e^{V2G}_{el,out}$	Pražnjenje pohrane električne energije	kW
e^{CHP}_{el}	Električna energija iz CHP postrojenja	kW
e^{imp}_{el}	Uvezena električna energija	kW
e^{exp}_{el}	Izvezena električna energija	kW
e^{HP}_{el}	Potražnja dizalice topline za el. energijom	kW
e^{CHP}_{th}	Toplinska energija iz CHP postrojenja	kW
e^{HP}_{th}	Toplinska energija iz dizalice topline	kW
$e^{TS}_{th,in}$	Punjenje pohrane toplinske energije	kW
$e^{TS}_{th,out}$	Pražnjenje pohrane toplinske energije	kW
SoC^{TS}	Stanje napunjenosti toplinske pohrane	GWh
SoC^{V2G}	Stanje napunjenosti električne pohrane	GWh
$e^{RES,ex}_{el}$	Višak električne energije iz OIE	kW

1. UVOD

1.1. STANJE OBNOVLJIVIH IZVORA ENERGIJE U EU




Slika 1-1. Sveukupni udio energije iz obnovljivih izvora

Na razini Europske Unije, cilj od 20% udjela obnovljivih izvora energije (OIE) u bruto finalnoj potrošnji energije (sve vrste energije - električna, toplinska i elektrokemijska) je dosegnut u 2019 godini (EK, 2020). Vidljiva je razlika između pojedinih zemalja unutar Unije, pri čemu neke zemlje jesu, a neke nisu ostvarile pojedinačne ciljeve i postotke.

Gledajući sve zemlje koje opisuje Eurostat-ova statistika, najveći udio imaju Island (zbog velikih geotermalnih resursa) i Norveška (zbog velikog hidro potencijala). Unutar EU najveći udio OIE ima Švedska, a najmanji Luxembourg, Malta i Nizozemska. Hrvatska je premašila svoj zadani cilj od 20% te je na 30% udjela.

Raspodjela potrošnje u sektoru transformacija prikazuje sljedeća slika:




Slika 1-2. Raspodjela potrošnje energije u sektoru transformacija

Vidimo da u sektoru transformacija kao ulaz u proizvodnju električne i toplinske energije prevladava nuklearna energija, kruta fosilna goriva i obnovljivi izvori energije. Na izlazu iz sektora transformacija dominantno je prisutna električna energija, s relativno malim udjelom toplinske energije. To znači da većina toplinske energije u finalnoj potrošnji dolazi od proizvodnje toplinske energije na mjestu potrošnje (npr. grijanje na krutu biomasu, plin, dizalice topline ili plitke geotermalne izvore energije).

Za usporedbu, dan je i pregled ulaza i izlaza iz rafinerija (koje također spadaju pod sektor transformacije), pri čemu je 100% energije iz fosilnih oblika energije - sirova nafta na ulazu, derivati na izlazu.

Sljedeća slika pokazuje sektore finalne potrošnje prema tipu goriva:




Slika 1-3. Potrošnja u odabranim sektorima po tipu energije

Vidimo da je promet najveći potrošač u sektoru finalne potrošnje, a slijede ga kućanstva i industrija te uslužni i javni sektor. Prema tipu finalne energije koja se koristi vidljive su velike razlike. Dok kućanstva primarno koriste prirodni plin i električnu energiju te obnovljive izvore (poglavito biomasu za grijanje), sektor prometa je dominantno u području kapljevitih derivata. Iz ove slike je vidljivo i koji je udio električne energije u sveukupnoj potrošnji, što je bitno jer dekarbonizacijom električne energije dekarboniziramo otprilike trećinu finalne potrošnje. Zato je bitno elektrificirati sektore finalne potrošnje istovremeno s dekarbonizacijom el. energije, u čemu pomažu obnovljivi izvori energije i njihova integracija u grijanje i promet, što će biti prikazano u ovom radu.


1.2 STANJE OBNOVLJIVIH IZVORA ENERGIJE U RH

Hrvatska je 2019. godine imala udio od 30% obnovljivih izvora energije u bruto finalnoj potrošnji energije. To je posljedica proizvodnje električne energije u hidroelektranama, vjetroelektranama i ostalim obnovljivim izvorima energije, ali i korištenju krute biomase za potrebe grijanja (EuH, 2018). Kao i kod ostalih zemalja EU, problem predstavlja uvođenje obnovljivih izvora energije u sektor prometa, koji je 97% pokriven fosilnim gorivima.




Slika 1-4. Udjeli energije za energetske transformacije (EuH, 2018)

Ulaz u sektor energetskih transformacija je dominantno u području kapljevitih goriva zbog rafinerija. Slijede vodne snage i plinovita goriva (pogon uglavnom kogeneracijskih postrojenja) te obnovljivi izvori energije i ugljen (termoelektrana Plomin 2).



Slika 1-5. Proizvodnja transformiranih oblika energije (EuH, 2018)


Dominantni su fosilni derivati, slijede električna energija, kao i para i vrela voda. Vrela voda se koristi u sustavima centraliziranog grijanja (toplane) i industriji, dok se para koristi samo u industriji. Plinovita goriva su rezultat degazoliranja za proizvodnju ukapljenog naftnog plina.



Slika 1-6. Udjeli sektora u neposrednoj potrošnji energije (EuH, 2018)

Vidimo da je u Hrvatskoj također sektor prometa zaslužan za jednu trećinu neposredne potrošnje energije, dok opća potrošnja koju čine kućanstva i javni sektor i sektor usluga zauzima polovicu udjela. Udio potrošnje energije u industriji je nešto niži nego prosjek EU.

Vidljivo je da i u Hrvatskoj najveći izazov predstavlja dekarbonizacija prometa kao najvećeg potrošača emisijski intenzivnih fosilnih goriva. Promet je zaslužan i za najveću emisiju CO₂, kako prikazuje sljedeća slika.



Slika 1-7. Trend emisija CO₂ uslijed izgaranja goriva (EuH, 2018)

Postrojenja za energetske transformacije (termoelektrane i elektrane), kao i sektor prometa čine gotovo dvije trećine ukupnih neto emisija u Hrvatskoj. Kako se na ulazu u energetske sektor očekuje povećanje udjela obnovljivih izvora energije, poglavito električne energije iz vjetroelektrana i solarnih elektrana, tako možemo zaključiti da je za uspješnu dekarbonizaciju ključna integracija tih izvora sa sektorima prometa i proizvodnje električne energije.

1.3 KLIMATSKI I ENERGETSKI CILJEVI EU DO 2030.

Zemlje članice država EU kroz svoje Nacionalne energetske i klimatske planove (engl. NECP) određuju kako će pridonijeti klimatskim i energetske ciljevima na razini Unije, za razdoblje od 2021.-2030. Planovi su također ključni ulazni podatak za planove oporavka i pravedne tranzicije zemalja članica.



Slika 1-8. Ciljevi EU u području ograničenja emisija do 2030. (prema EK, 2020b).

Povećana klimatska ambicija nudi mogućnost ubrzanja modernizacije ekonomije i podupire inovacije te stvara temelj održivom razvoju.



Slika 1-9. Ciljevi EU u području OIE do 2030. (prema EK, 2020b)

Primjeri kako neke od država EU planiraju postići svoje ciljeve:

- Austrija – planira instalirati 100 000 krovnih solarnih panela
- Litva – nudi financijsku potporu korisnicima za izgradnju malih (engl. small scale) energana sa očekivanim ishodom od 696MW instaliranog kapaciteta
- Danska – planira investicijama ostvariti 4GW odobalnog kapaciteta vjetroelektrana
- Francuska – planira ugovoriti šest tendera za odobalne VE do 2023., ciljajući na 3,7GW kapaciteta

- Grčka i Portugal – planiraju izgraditi solarne elektrane i infrastrukturu za vodik u zatvorenim rudnicima lignita. (EK, 2020)

Europska komisija navodi energetska učinkovitost kao prioritet za čistu energetska tranziciju te provodi nove inicijative, poput *Renovacijskog vala*, kako bi ubrzala proces, primarno u građevinskom sektoru. (MGiPU, 2020)



Slika 1-10. Ciljevi EU u području energetska efikasnosti do 2030. (prema EK, 2020b)

1.4. UMJETNA NEURONSKA MREŽA - GENERALNI PRINCIP

Umjetna neuronska mreža je naziv za tehniku izrade računalnog programa koji uči iz skupa ulaznih podataka, odnosno iskustva, te razumije svijet u smislu hijerarhije koncepata. Konceptualno je izvedena iz principa na koji mislimo da ljudski mozak funkcionira. (Goodfellow et al., 2016)

Prvo je stvorena i međusobno povezana kolekcija softverskih „neurona“, što im omogućuje da međusobno izmjenjuju signale.

Nakon toga, mrežu se traži da riješi zadani problem, a kroz mnogobrojne pokušaje svaki put ojačava konekcije koje vode uspjehu, a umanjuje one koje vode ka neuspjehu. Mreža se sastoji od ulaznog i izlaznog sloja neurona, između kojih se nalaze tzv. skriveni slojevi – oni predstavljaju računalnu sposobnost mreže. Neuronski slojevi rade razne matematičke transformacije nad ulaznim podacima te na izlazu iz zadnjeg sloja se nudi rješenje zadatka.

Dubina mreže podrazumijeva broj skrivenih slojeva te se učenje sa više skrivenih slojeva naziva *duboko učenje* (engl. deep learning). Sa dubinom mreže progresivno raste i njen kapacitet shvaćanja sve apstraktnijih pojmova i uzoraka.


Arhitektura, ili topologija, mreže podrazumijeva strukturu – broj slojeva, broj neurona u svakom sloju te način povezanosti slojeva kroz razne strukture. Neuroni između dva susjedna sloja mogu biti potpuno spojeni, što znači da je svaki neuron spojen sa svima iz susjednog sloja. U drugom slučaju, grupa neurona iz jednog sloja može biti spojena sa samo jednim iz sljedećeg sloja (engl. pooling). Ako su sve veze u sloju usmjerene u sljedeći sloj, naziva se aciklička (engl. feedforward) mreža, a ako postoje veze između neurona u istom, ili prethodnom sloju, radi se o rekurentnim (povratnim) mrežama.

Svaki **neuron** je čvor spojen sa drugim čvorovima preko veza koje simuliraju biološke akson-sinapsa-dendrit spojeve, a svaka veza ima ponder, koeficijent težine - uteg (engl. weight), koji predstavlja snagu utjecaja jednog čvora na drugi, odnosno relativnu važnost. Neuron ima ulazne podatke (ulazni podaci u mrežu ili izlazne vrijednosti prethodnih neurona) te stvara jednu izlaznu vrijednost koja se dalje može slati višestrukim neuronima. Izlazna vrijednost zadnjeg (sloja) neurona je rješenje zadanog problema.

Funkcija razmnožavanja (engl. propagation function) računa ulaznu vrijednost u čvor kao ponderirani zbroj izlaznih vrijednosti svih povezanih prethodnih neurona. Rezultatu propagacije se može pribrojati dodatna konstanta - *pristranost* (engl. bias term). Ta vrijednost prolazi kroz aktivacijsku funkciju kako bi se izračunala konačna izlazna vrijednost pojedinog neurona.

Aktivacijska funkcija je jedan od temeljnih faktora o kojem će ovisiti uspjeh mreže. Bez nje, izlazne vrijednosti pojedinog neurona mogu varirati ($-Inf$, $+Inf$), tako da neuroni zapravo ne znaju granice svojih vrijednosti. Uz to, ta vrijednost bi bila samo linearna suma svih ulaznih vrijednosti. Iz tih razloga, aktivacijska funkcija ima tri svrhe (Feng, 2019.):

- na temelju ulaznih vrijednosti određuje da li bi se neuron trebao aktivirati ili ne te na taj način unosi veliku količinu nelinearnosti u model.
- transformira izlazne vrijednosti u granicama (0,1) ili (-1,1) kako bi dimenzionalnost i rukovanje sa brojevima bilo kontrolirano i efikasno.
- svojom derivabilnošću (svojstvom lagane derivacije) olakšava i ubrzava povratnu propagaciju.



Slika 1-11. Tipične aktivacijske funkcije (AI Wiki, 2021)

Hiperparametri su konstantne vrijednosti (intuitivno) određene prije nego što učenje započne, a neki od njih su: stopa učenja, broj skrivenih slojeva, veličina trenažne serije (engl. batch size) te funkcija troška – mjera uspjeha mreže (engl. cost function).

Povratna propagacija (engl. backpropagation) je metoda kojom se namještaju (nasumično inicijalizirani) koeficijenti težine (utezi) između čvorova mreže kako bi se kompenzirala greška tokom učenja. Metoda računa gradijent, tj. derivaciju, funkcije troška za pojedino stanje u ovisnosti o koeficijentima težine te ih zatim ažurira traženjem globalnog minimuma funkcije troška.

U ovisnosti o vrsti problemskog zadatka, tri su **glavne paradigme učenja**:

1) Nadzirano učenje (engl. supervised learning) – koristi set uparenih ulaznih i željenih izlaznih podataka. Primjereno za zadatke prepoznavanja uzoraka – klasifikacije i aproksimacije funkcija – regresije. Ovaj tip učenja je implementiran u ovome radu.

2) Učenje bez nadzora (engl. unsupervised learning) – učenje iz neoznačenog seta izlaznih podataka. Model je prisiljen stvoriti unutarnju reprezentaciju „svijeta“ te zatim generirati sadržaj. Za razliku od nadziranog učenja, model pokazuje samo-organizaciju koja bilježi uzorke (engl. patterns) kao neuronske sklonosti odnosno gustoće vjerojatnosti.

3) Potpomognuto učenje (engl. reinforcement learning) – paradigma u kojoj agent napravi niz radnji, dobije odziv od okoline te nastoji razviti strategiju kojom će „pobijediti“, odnosno generirati radnje koje minimiziraju dugoročni (očekivani kumulativni) trošak. Problemi za koje se koristi uključuju video igre, regulacijske i kontrolne sustave te druge sekvencijalne zadatke koji uključuju donošenje odluka.

Dva su **načina učenja** – stohastičko i u seriji (engl. batch). Kod stohastičkog učenja, svaki ulazni podatak rezultira ažuriranjem koeficijenata težine. Pri učenju u seriji, koeficijenti su ažurirani na temelju cijele serije ulaznih podataka, akumulirajući greške kroz seriju.


Stohastičko učenje unosi „buku“ (engl. noise) u proces, koristeći lokalni gradijent izračunat iz samo jedne točke podataka, što smanjuje vjerojatnost da mreža zapne u lokalnom minimumu. No, treniranje u seriji tipično rezultira bržem i stabilnijem spustu u lokalni minimum pošto je svako ažuriranje izvedeno u smjeru prosječne greške cijele serije. Kompromis je pri korištenju tzv. mini-serija – male serije sa stohastički izabranim uzorcima iz cjelokupnog skupa podataka.

Tipovi umjetnih neuronskih mreža

Kod osnovnog tipa, komponente mreže (broj slojeva, broj čvorova, topologija) su statične. Dinamični tip mreže dopušta da, u većoj ili manjoj mjeri, ove komponente evoluiraju tokom učenja. Takve mreže su puno kompliciranije, ali mogu skratiti vrijeme učenja i konvergirati ka boljem rješenju.

Bitna su otkrića u ovome području:

1) Konvolucijske neuronske mreže – posebno uspješne u procesuiranju vizualnih i ostalih dvodimenzionalnih podataka, u kojima prepoznaju značajke (engl. features) raznih kompleksnosti te stvaraju hijerarhijsku strukturu nad njima (LeCun et al., 1998), formirajući pritom karte značajki (engl. feature map).

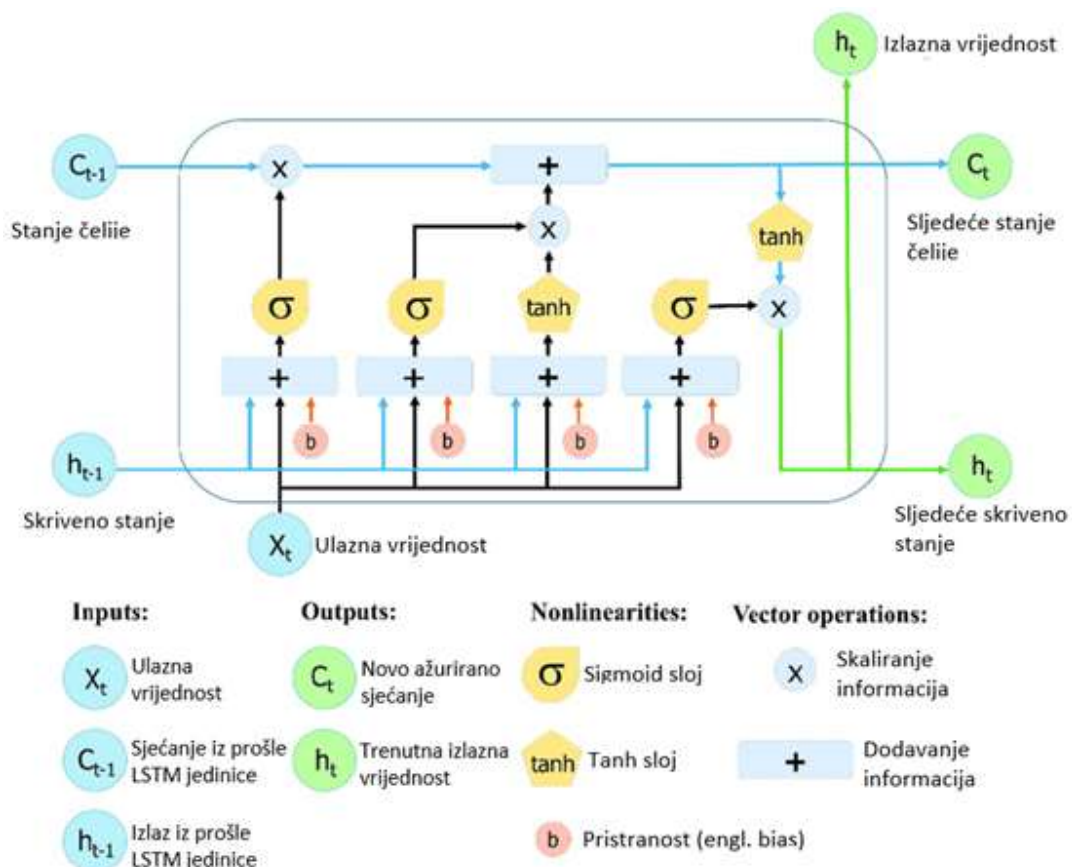


Slika 1-12. Shema konvolucijskog procesa (prema Singh et al., 2020)



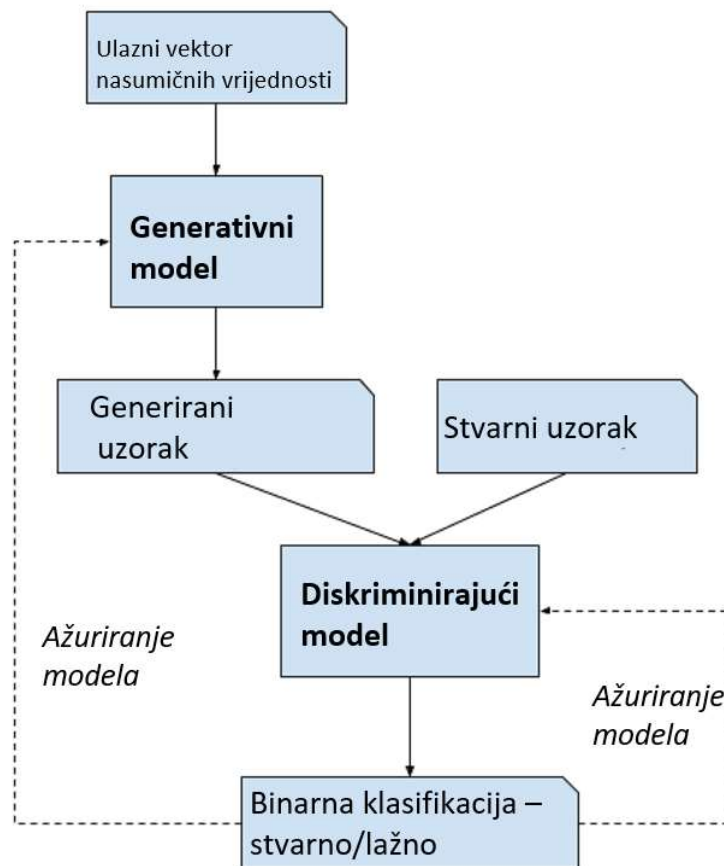
Slika 1-13. Primjer vizualizacije karte značajki korištenjem metode „dubokog sna“ (engl. deep dream) na modelu mreže za klasifikaciju slika – u izdvojenu kartu iz određenog sloja se ubacuje ulazna fotografija na način da maksimizira aktivaciju tog sloja. Time značajke koje mreža traži (u tom sloju, odnosno na toj razini apstrakcije) postaju vidljive (Kiverstein, 2019)

2) LSTM (engl. long short-term memory) – povratni tip mreže koji može procesuirati signale koji imaju miks niskih i visokih frekvencijskih komponenti, a pokazala se uspješnom u zadacima prepoznavanja govora, pretvaranja teksta u govor te stvaranju foto-realističnih glava koje govore. (Sherstinsky, 2018.)



Slika 1-14. Struktura LSTM neuronske mreže (prema Lee i Jung, 2019)

3) Generativne suparničke mreže (engl. GAN) – sastoje se od višestrukih mreža različite strukture koje se međusobno natječu, i uče, u zadacima poput pobjede u igri, ili varanja „protivnika“ o autentičnosti signala.



Slika 1-15. Primjer arhitekture generativne suparničke mreže. (prema Brownlee, 2019)

1.5. KONSTRUKCIJA NEURONSKE MREŽE S OBZIROM NA KOMPLEKSNOST I TIP ULAZNIH PODATAKA

Pri konstruiranju neuronske mreže, najvažniji čimbenik je tip podataka i vrsta problemskog rješenja. Tipični primjeri ulaznih podataka su: slike, vremenske serije te tekstualni, audio ili video podaci. Vrsta rješenja, odnosno zadatka, može biti klasifikacija ili regresija, odnosno predviđanje.

Za klasifikacijske probleme je specifično da u posljednjem sloju mreže koriste normaliziranu eksponencijalnu aktivacijsku funkciju (engl. softmax function), koja služi kako bi se izlazni podaci normalizirali u distribuciju vjerojatnosti nad predviđanjima izlaznih klasa problema. (Gao, 2017)

Kada neuronske mreže riješe problem, na određeni način i utjelovljuju kompleksnost tog problema. Zbog toga, kako raste razina kompleksnosti problema, tako raste i minimalna kompleksnost mreže koja ga rješava. Ovo je specifična formulacija generalnog vjerovanja u teoriji sistema, a to je da kako okruženje postaje složenije, tako i kognitivni sustav koji je u njega ugrađen postaje sve složeniji (Baeldung, 2020). Računalo uči iz iterativnog iskustva i razumije svijet u smislu hijerarhije različitih koncepata, gdje je svaki (koncept) definiran kroz svoj odnos sa jednostavnijim konceptima.

Tipična mjera za kompleksnost modela u strojnom učenju je dimenzionalnost parametara učenja, jer proračunski trošak povratne propagacije raste naglo i za male promjene u dimenzionalnosti parametara – a posebno je naglašeno prilikom korištenja nelinearnih aktivacijskih funkcija. To vodi problemu poznatom kao **prokletstvo dimenzionalnosti** (engl. the curse of dimensionality). Neke mrežne arhitekture, poput konvolucijske, rješavaju ovaj problem iskorištavajući linearnu ovisnost ulaznih varijabli. Druge, poput regresijskih, to ne mogu, te im vrijeme treniranja traje znatno duže.

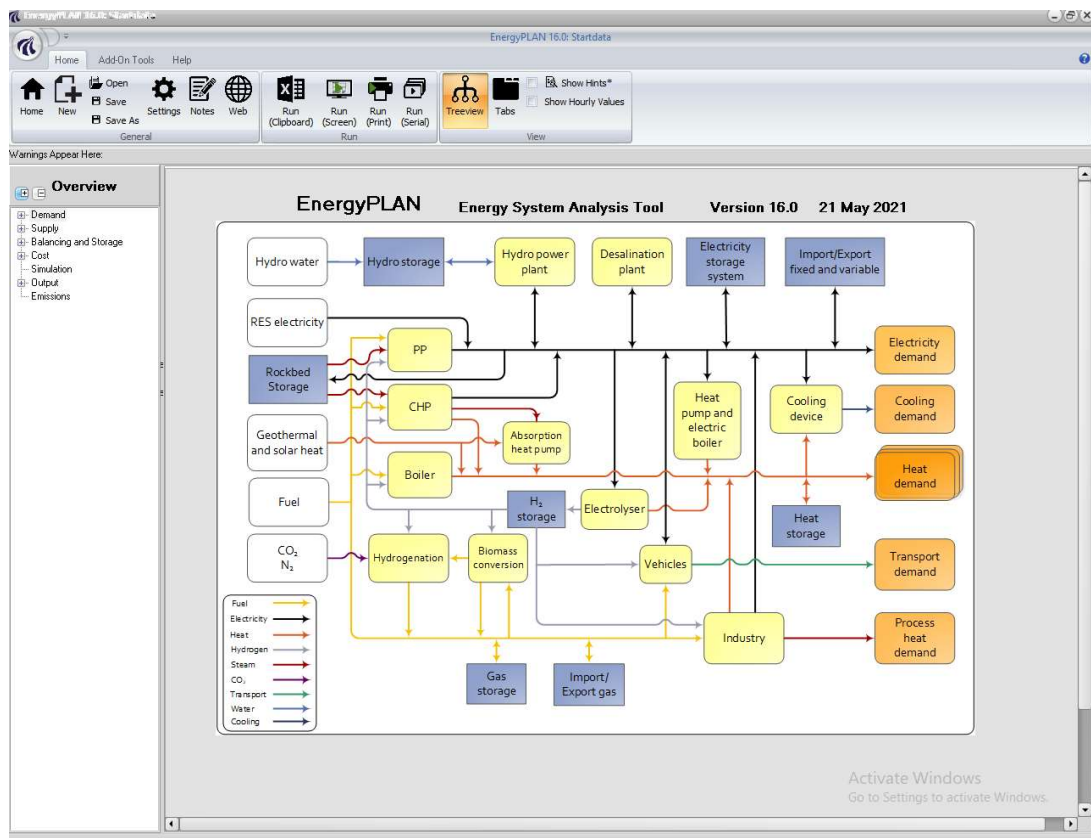
Zbog toga, bitno je identificirati neuronske mreže minimalne kompleksnosti i proračunskog troška, za zadani problem.

Pretraživanje neuralne arhitekture koristi strojno učenje za automatizaciju dizajna mreže. Osnovni algoritam pretraživanja je da se predloži model kandidat, procijeni se u odnosu na skup podataka te se rezultati koriste kao povratna informacija mreži koja traži optimalni dizajn. Dostupni su sustavi AutoML i AutoKeras. Ova metoda nije korištena za potrebe ovoga rada.

2. METODA

Za simulaciju djelovanja energetskeg sustava korišten je računalni model za naprednu analizu energetskeg sustava EnergyPLAN. Na temelju izlaznih podataka iz simulacije – godišnjih energetskeg tokova te energetskeg bilanci, konstruirana je umjetna neuronska mreža. Izlazni podaci simulacije su korišteni kao ulazni podaci u mrežu, na kojima je trenirana (slika 3-1.). Izlazni rezultat mreže je prognoza budućih kontrolnih vrijednosti, relevantnih za vođenje, odnosno upravljanje energetskeg mikro-mrežom te planiranju buduće potrošnje.


2.1. EnergyPLAN



Slika 2-1. Prikaz naslovnog prozora (EnergyPLAN, 2021)

EnergyPLAN (Lund, 2021) je programski alat za analizu energetskeg sustava, stvoren za proučavanje i istraživanje dizajna budućih održivih energetskeg rješenja, s posebnim fokusom

na energetske sustave sa visokim udjelom obnovljivih izvora energije. Posebno je dizajniran da iskoristi moguće sinergije koje nastaju kada se analizira cjelokupni energetski sustav, izražene kroz koncept *pametnih energetskih sustava*. Zbog toga, korisniku omogućava holistički pristup problemu, sa fokusom na međusektorsku interakciju. Potražnja u sektorima koji su tradicionalno smatrani zasebno, poput zgrada, industrije i transporta, su povezani preko tehnologija ponude kroz električnu energiju, prirodni plin, daljinsko grijanje i rashladne mreže. Na ovaj način EnergyPLAN omogućuje analizu konverzije el. energije iz obnovljivih izbora u druge energetske oblike, poput topline, vodika, *zelenih plinova* i elektro goriva te implementaciju poboljšanja energetske učinkovitosti i konverziju energije.

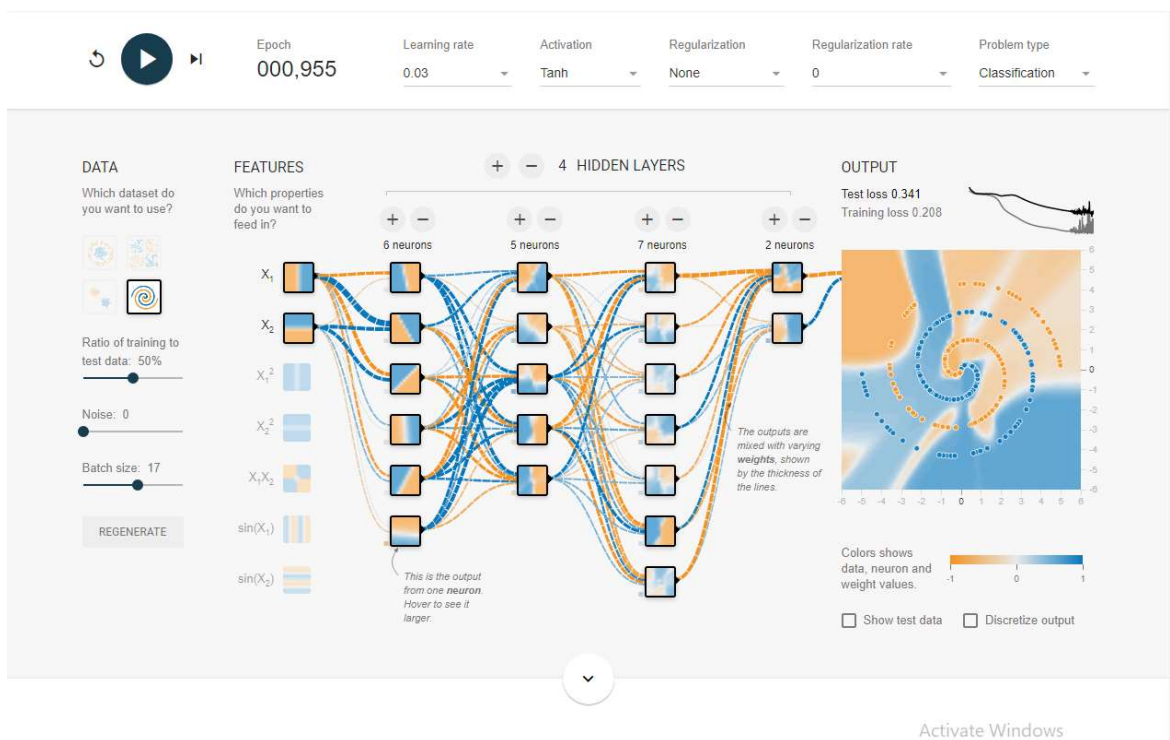


Slika 2-2. Primjer unosa toplinske potražnje analiziranog sustava (EnergyPLAN, 2021)

2.2. UMJETNA NEURONSKA MREŽA – TENSORFLOW

TensorFlow je softverska biblioteka otvorenog koda za strojno učenje, a ima poseban fokus na treniranje i konstruiranje dubokih neuronskih mreža (engl. deep neural networks). Simbolična je matematička biblioteka koja se temelji na protoku podataka i diferenciranom programiranju, što omogućava optimizaciju na bazi gradijenta greške (engl. gradient based optimization – gradient descent). Koristi se za istraživanje i proizvodnju u Google-u, a razvijena je od strane tima Google Brain za internu upotrebu te javno izdana 2015. godine. Fleksibilna arhitektura omogućava jednostavnu implementaciju izračuna preko različitih (računalnih) platformi (CPU, GPU, TPU) te od mobilnih uređaja i stolnih računala do klastera servera. Izračuni TensorFlow-a izraženi su kao grafovi protoka podataka sa statusom stanja (engl. stateful dataflow graphs). Ime biblioteke dolazi od operacija koje takva neuronska mreža radi na višedimenzionalnim nizovima podataka, koje se naziva tenzorima.

Za potrebe ovoga rada, TensorFlow je implementiran u programskom jeziku Python.

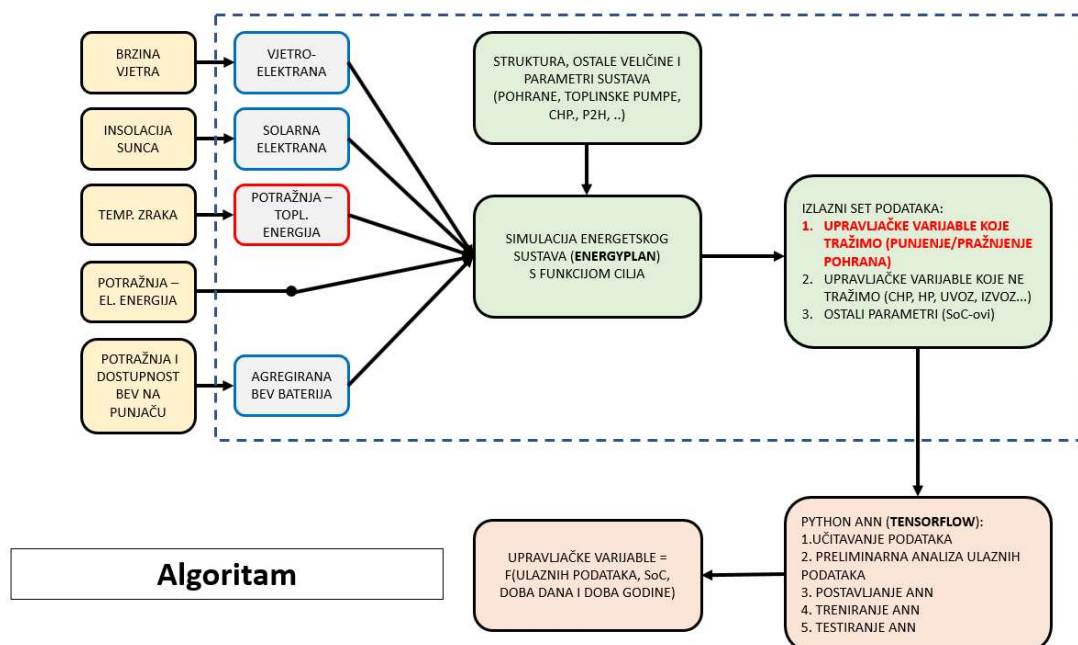


Slika 2-3. TensorFlow Playground – web lokacija za eksperimentiranje sa arhitekturama pri analizi tipičnih problemskih zadataka (<https://playground.tensorflow.org/>, 2021)

3. ANALIZA SLUČAJA

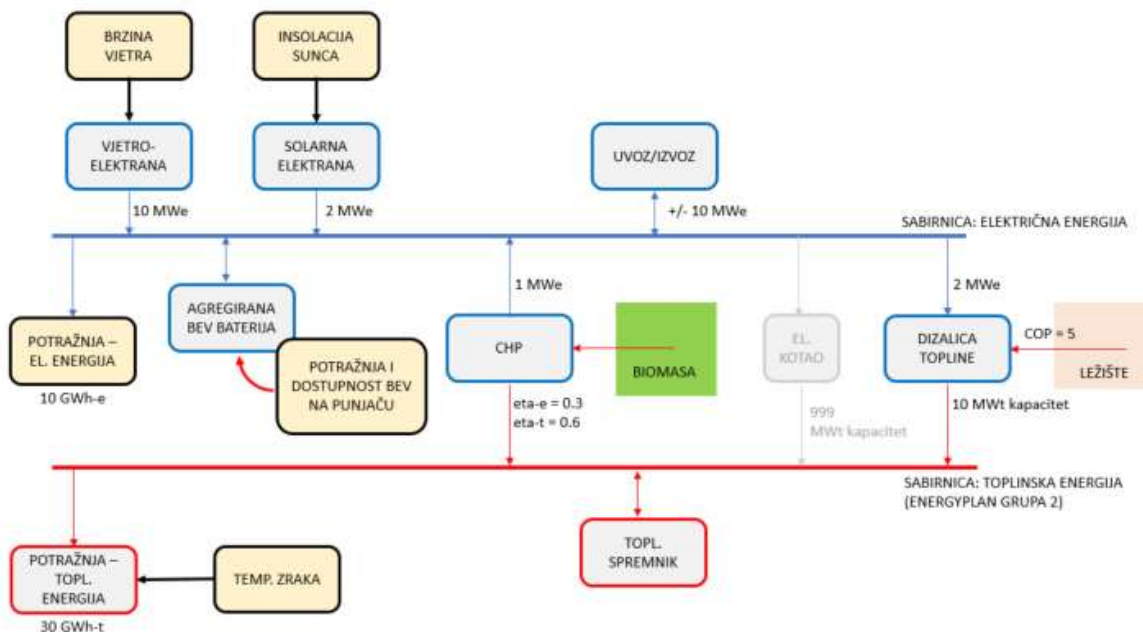
3.1. POSTAVKE ANALIZE SLUČAJA ZA EnergyPLAN

Na slici 3-1. je prikazana shema cjelokupnog modela – simulacijski model koristi ulazne informacije; poput brzine vjeta, insolacije sunca, temperature zraka, potražnja za električnom energijom te dostupnost i potražnja BEV na punjaču; te simulira godišnji energetske tok za zadani sustav.



Slika 3-1. Shema cjelokupnog modela

Simulirani model energetske mikro-mreže uključuje zajednicu od dvije tisuće kućanstava sa potrošnjom od 5MWh električne i 15MWh toplinske energije te prijeđenih 15 000km automobilom godišnje, po kućanstvu. Automobili su pretpostavljeni kao baterijska električna vozila (BEV) te osim za mobilnost, imaju i ulogu pohrane električne energije, sa 0,1 GWh kapacitetom pohrane.




Slika 3-2. Shema analiziranog energetskeg sustava (EnergyPLAN)

Izvori električne energije su vjetroelektrana snage 4MWe, solarna elektrana snage 8MWe, kogeneracijsko postrojenje za proizvodnju električne (1MWe) i toplinske (2MWt) energije te uvoz iz (a moguć je i izvoz u) javne distribucijske električne mreže, kapaciteta 10MWe.

Izvor toplinske energije je prvenstveno toplinska pumpa snage 2MWe koja koristi plitko geotermalno ležište kao rezervoar toplinske energije. Sa koeficijentom djelovanja, $COP = 5$, dodaje 10MWt toplinske energije u sabirnicu toplinske energije. Kao dodatak je toplina iz kogeneracijskog (engl. combined heat and power, CHP) postrojenja na biomasu, toplinske snage 2MWt, kada se ne koristi toplinska pumpa. Za dodatnu fleksibilnost i učinkovitost, sustav ima i toplinski spremnik , kapaciteta 2GWh.

U ovome sustavu, agregirana BEV baterija predstavlja (u vremenu) promjenjivu pohranu, a toplinski spremnik nepromjenjivu.



Slika 3-3. Prikaz rezultata simulacije (EnergyPLAN)

S obzirom na kompleksnost modela, ovdje predstavljena metoda opisuje bilanciranje samo onih energetskekih tokova koji su relevantni za model kojeg analiziramo u ovome diplomskom radu, a prikazan je na slici 3-1. Bilanciraju se tokovi električne i toplinske energije:

$$\underbrace{(d_{el} + e_{el}^{HP} + e_{el,in}^{V2G} + e_{el}^{exp})}_\text{potražnja} = \underbrace{(e_{el}^{PV} + e_{el}^W + e_{el}^{CHP} + e_{el}^{imp} + e_{el}^{V2G})}_\text{ponuda} \quad (3-1)$$

$$\underbrace{(d_{th} + e_{th,in}^{TS})}_\text{potražnja} = \underbrace{(e_{th}^{CHP} + e_{th,out}^{TS} + e_{th}^{HP})}_\text{ponuda} \quad (3-2)$$

Prva jednađzba nam govori da je zbroj potražnje za električnom energijom, kao i potražnje dizalice topline i električnih vozila jednak dobavi iz varijabilnih obnovljivih izvora energije, CHP postrojenja i iz baterije električnih vozila. Sav eventualni višak energije ide u izvoz, a manjak se pokriva uvozom. Kod toplinske energije imamo manje elemenata sustava, te je sva potražnja pokrivena ili iz CHP postrojenja ili toplinske pumpe. Eventualni višak toplinske energije se može pohraniti u toplinski spremnik za kasniju dobavu.

Pri tome treba definirati i dopunske jednadžbe koje povezuju električne i toplinske tokove. Za toplinsku pumpu imamo:

$$(e_{el}^{HP})_t = \frac{(e_{th}^{HP})_t}{COP} \quad (3-3)$$

Za CHP postrojenje imamo:

$$(e_{el}^{CHP})_t = (e_{primar}^{CHP})_t \cdot \eta_{el} \quad (3-4)$$

$$(e_{th}^{CHP})_t = (e_{primar}^{CHP})_t \cdot \eta_{th} \quad (3-5)$$

pri čemu je e_{primar}^{CHP} primarna energija na ulazu u CHP. Ta primarna energija može biti fosilno gorivo (ugljen, plin, kapljeviti derivat) ili kruta, plinovita ili kapljevita biomasa. Ostaje jednadžba za pohranu električne i toplinske energije. Za toplinsku energiju jednadžba je relativno jednostavna:

$$0 \leq (SoC^{TS})_t = (SoC^{TS})_{t-1} + \left(e_{th,in}^{TS} \eta^{TS} - \frac{e_{th,out}^{TS}}{\eta^{TS}} \right)_t \leq \underbrace{SoC_{max}^{TS}}_{konstantan\ u\ vremenu} \quad (3-6)$$

Stanje napunjenosti u novom vremenskom trenutku jednako je stanju napunjenosti u prethodnom vremenskom trenutku uvećanom i umanjenom za neto toplinske tokove prema i iz toplinskog spremnika. Maksimalna vrijednost toplinskog spremnika je nepromjenjiva u vremenu.

Za pohranu u baterije električnog vozila situacija je kompliciranija, s obzirom na to da imamo agregirani kapacitet baterije koji se mijenja u vremenu, s obzirom na promjenjivi broj BEV koji su „na punjaču“.

$$0 \leq (SoC^{V2G})_t = (SoC^{V2G})_{t-1} + \left(e_{el,in}^{V2G} \eta^{V2G} - \frac{e_{el,out}^{V2G}}{\eta^{V2G}} - d_{el}^{BEV} \right)_t \leq \underbrace{(SoC_{max}^{V2G})_t}_{promjenjiv\ u\ vremenu} \quad (3-7)$$

Zadatak programa EnergyPLAN je da, koristeći raspoložive elemente dobave, zadovolji potražnje d_{el} , d_{th} i d_{el}^{BEV} . Do rješenja je moguće doći na bezbroj načina, međutim,


EnergyPLAN optimira energetske tokove sustava da zadovolji optimum minimalne izmjene električne energije s vanjskim sustavom, tj. da minimizira e_{el}^{imp} i e_{el}^{exp} , pri tome maksimalno koristeći raspoloživu energiju iz vjetroelektrana i PV-a. Iz tog razloga, i svi mrežom naučeni principi će u sebi imati ugrađenu ovu zakonitost, odnosno ovaj cilj. Datum početka simulacije je 01.01.

S obzirom na vrijednosti ulaznih podataka (poglavito krivulje potražnje i dobave iz OIE), karakter pohrane za toplinsku energiju će najčešće biti sezonski. Rezultati simulacije predstavljaju satne vrijednosti svih (optimiranih) energetskih tokova za jednu godinu te se pohranjuju u Excel datoteku.

**Rezultati - Excel
(EnergyPLAN)**

		d_{el}	d_{th}	d_{el}^{BEV}	e_{el}^W	e_{el}^{PV}	e_{el}^{V2G}	e_{el}^{CHP}	e_{el}^{imp}	e_{el}^{HP}	e_{el}^{V2G}	e_{el}^{exp}	e_{th}^{CHP}	e_{th}^{HP}	$T_{S,th,in}$	$T_{S,th,out}$	SoC_{V2G}	SoC_{TTS}		
	Hour	$e_{dem,el}$	$e_{dem,th}$	$e_{dem,EV}$	$sup_{,PV}$	$sup_{,W}$	$sup_{,el,V2G,dch}$	$sup_{,el,CHP}$	$sup_{,el,imp}$	$e_{dem,HP}$	$e_{dem,el,V2G,chg}$	$e_{dem,el,exp}$	$sup_{,th,CHP}$	$sup_{,th,HP}$	$sup_{,th,storage}$	$e_{dem,th,storage}$	SoC_{V2G}	$SoC_{thermal}$	$balance_{el}$	$balance_{th}$
1	1	992	6748	1230	0	388	0	1000	1366	396	1366	0	2000	1980	2768	0	0	938931	0	0
2	2	934	6748	1230	0	532	0	1000	1366	598	1366	0	2000	2991	1757	0	0	937175	0	0
3	3	906	6748	1230	0	800	0	1000	1366	894	1366	0	2000	4469	279	0	0	936896	0	0
4	4	865	6748	1230	0	1044	0	836	1366	1015	1366	0	1673	5075	0	0	0	936896	0	0
5	5	829	6748	1230	0	1500	0	484	1366	1156	1366	0	969	5779	0	0	0	936896	-1	0
6	6	808	6748	1230	0	1232	0	661	1366	1085	1366	0	1322	5426	0	0	0	936896	0	0
7	7	814	6748	1230	0	1236	0	663	1366	1084	1366	0	1325	5422	0	0	0	936896	1	-1
8	8	839	6748	0	0	1720	0	334	0	1216	0	0	669	6079	0	0	0	936896	-1	0
9	9	864	6748	0	0	1544	0	408	0	1186	0	0	817	5931	0	0	0	936896	0	0
10	10	885	6748	0	0	1344	0	513	0	1144	0	0	1027	5721	0	0	0	936896	0	0
11	11	933	6748	0	0	499	0	111	0	1305	0	0	222	6526	0	0	0	936896	0	0
12	12	983	6748	0	0	939	0	0	0	1460	0	0	0	7299	0	552	0	937447	0	-1
13	13	1017	6748	0	0	1216	0	0	0	1759	0	0	0	8797	0	2049	0	939496	0	0
14	14	1026	6748	0	0	1139	0	0	0	1389	0	0	0	6946	0	198	0	939695	0	0
15	15	1027	6748	0	0	760	0	55	0	1327	0	0	110	6637	0	0	0	939695	1	-1
16	16	1039	6748	0	0	238	0	1520	0	451	0	0	902	5846	0	0	0	939695	1	0
17	17	1121	6748	0	0	1532	0	671	0	1081	0	0	1341	5407	0	0	0	939695	1	0
18	18	1230	6748	0	0	1284	0	926	0	979	0	0	1851	4897	0	0	0	939695	1	0
19	19	1252	6748	0	0	1048	0	1000	854	796	854	0	2000	3982	766	0	768	938929	0	0
20	20	1204	6748	1230	0	736	0	1000	939	532	939	0	2000	2660	2088	0	384	936841	0	0

Slika 3-4. Tablični prikaz rezultata simulacije



Slika 3-5. Jednodišnje krivulje rezultata simulacije

3.2. POSTAVKE ANALIZE SLUČAJA – ANN

3.2.1. Manipulacija ulaznim podacima i inženjering značajki

Inženjering značajki (engl. feature engineering) podrazumijeva analizu, pretprocesiranje i transformaciju, dekompoziciju, i ostale metode manipulacije ulaznim podacima u svrhu poboljšavanja učenja neuronske mreže.

Konstruirana neuronska mreža koristi pretpostavku da upravljačke varijable ovise o:

- stanju napunjenosti pohrana, $SoC(V2G)$ i $SoC(TS)$
- višku, odnosno manjku obnovljive električne energije za izravno pokrivanje potražnje ($e_{el_RES_ex}$), prema formuli (3-9)
- potražnji za električnom i toplinskom energijom
- pomoćnim signalima (sezonska i dnevna varijacija)


$$e_{el,in}^{V2G}, e_{el,out}^{V2G}, e_{th,in}^{TS}, e_{th,out}^{TS} = f(SoC^{V2G}, SoC^{TS}, e_{el}^{RES,ex}, d_{el}, d_{th}, sig_1, sig_2) \quad (3-8)$$

$$e_{el}^{RES,ex} = e_{el}^W + e_{el}^{PV} - d_{el} - d_{el}^{BEV} - \frac{d_{th}}{COP} \rightarrow \text{višak obnovljive struje} \quad (3-9)$$

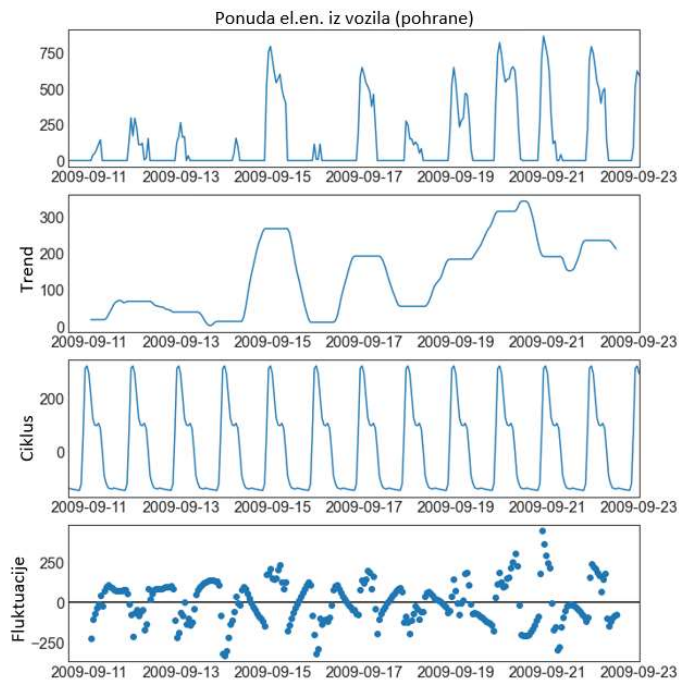
$sig_1, sig_2 \rightarrow$ pomoćni signali za dnevnu i sezonsku varijaciju

Prvi korak u razvoju umjetne neuronske mreže je analiza ulaznog seta podataka te problemskog zadatka. Izlaz dvogodišnje simulacije EnergyPLAN-a (slika 3-3) je vremenski slijed dužine 17 568 (broj sati u dvije godine) sa 19 značajki - 2D matrica dimenzije (17568x19).


Nepotrebni, ili ne-korisni, podaci značajno produžuju treniranje i smanjuju mogućnost mreže da uči. Stoga se prvo provodi analiza ulaznih podataka.



Slika 3-6. Dekompozicija vremenske serije punjenja BEV-a. Grafovi pokazuju trend, cikličnost te nepravilne komponente (kratkoročne fluktuacije)




Slika 3-7. Dekompozicija vremenske serije pražnjenja BEV-a. Grafovi pokazuju trend, cikličnost te nepravilne komponente (kratkoročne fluktuacije)



Slika 3-8. Fourierova transformacija krivulja potražnje za električnom i toplinskom energijom. Vršne vrijednosti prikazuju dominantne frekvencije.


Sa slike 3-8 je vidljivo kako toplinska potražnja ima izuzetnu godišnju cikličnost, dok električnom dominira dnevna, tjedna i unutar dnevna cikličnost.




Slika 3-9. Fourierova transformacija krivulje punjenja električne pohrane

Krivulja punjenja pohrane električne energije pokazuje izrazitu dnevnu i unutar dnevnu cikličnost – slika 3-9.

Na temelju ove analize može se zaključiti da bi signal za dnevno, unutar dnevno, tjedno i sezonsko unutarnje stanje modela mogao mreži olakšati proces treniranja i buduće prognoze.




Slika 3-10. Krivulje rezultata simulacije, za interval od jednog tjedna, sa dodanim signalima




Slika 3-11. Korelacijske vrijednosti simulacijskih varijabli i konstruiranih signala


Kao ulazni podaci u mrežu izabrane su sljedeće varijable: višak, odnosno manjak električne energije iz OIE, stanje toplinskog spremnika, stanje električnog spremnika; te dodatni signali za OIE (vjetar i sunce) i potražnju za toplinskom energijom. Signali su konstruirani metodom diskretne Fourierove transformacije, na način da se poklapaju sa temeljnim krivuljama.



Slika 3-12. Korelacijske vrijednosti odabranih ulaznih varijabli



Slika 3-13. Prikaz krivulja odabranih ulaznih varijabli za zadnji tjedan simulacije



Slika 3-14. Prikaz krivulja odabranih ulaznih varijabli za dvije godine simulacije

3.2.2. Priprema ulaznih podataka u model

Kako bi se adekvatno pripremili ulazni nizovi (engl. array) u sami model, prvo je potrebno odlučiti se za dva parametra – broj dana (sati) „pogleda unazad“ koji mreža koristi kao temelj za prognozu traženih vrijednosti jedan sat unaprijed, te broj dana (sati) prognoze u budućnost.

U ovome slučaju, tražena je **prognoza od jednog tjedna (168 sati)** unaprijed, a za prvi parametar izabrana je vrijednost od **24 sata**.

Smatra se kako ta vrijednost najbolje, ili sasvim dovoljno dobro, shvaća trendove u promjenama vrijednostima ulaznih podataka. Nepotrebno velika vrijednost eksponencijalno povećava količinu podataka i trajanje izračuna, a može i smanjiti konačnu kvalitetu rezultata na način da unosi „buku“ u model.

Sljedeći korak je odvajanje ulaznih podataka u tri kategorije:

- set podataka za treniranje
- set podataka za potvrđivanje kvalitete rezultata (engl. validation set)
- set podataka za testiranje

Set podataka za testiranje je zadnji tjedan (+ jedan dan) u drugoj godini simulacije – taj tjedan će biti prognoziran te uspoređen sa „stvarnim“ vrijednostima simulacije. Ove podatke mreža (niti operator) nije vidjela u cijelom procesu treniranja i optimiziranja. Taj rezultat određuje kvalitetu cjelokupnog performansa mreže. U drugim slučajevima, dodatna metrika može biti i trajanje treniranja te kompleksnost izrade (broj linija kôda).

Set za validaciju je određen kao 10% seta za treniranje te služi kao mjera za optimiziranje topologije i hiperparametara mreže, a razlika između funkcije gubitka seta za treniranje i seta za validaciju daje naznake o kvaliteti i tipu učenja.

Set za treniranje se sastoji od ostalih (prvih) 17376 unosa 5 odabranih značajki, a matričnog je oblika dimenzija **(17376x5)**. Za prva 23 unosa se neće tražiti izlazna vrijednost pošto nemamo punu dužinu povijesnih unosa (u iznosu od 24 sata).

Set za testiranje po istoj je logici oblika **(192x5)**.

Na vrijednostima ulaznih značajki/varijabli napravljena je matematička transformacija skaliranja u zadanom rasponu (od 0÷1) – normalizacija. Varijable sa velikom raspodjelom vrijednosti mogu rezultirati sa velikim vrijednostima gradijenta greške i time uzrokovati da se vrijednosti utega drastično mijenjaju. Ovaj korak je izuzetno bitan kako bi proces učenja bio stabilan, a spust gradijenta brže konvergirao minimumu.. Stabilnost je rezultat „glatkog“ spuštanja gradijenta prema minimumu jer su utezi ažurirani jednakom stopom za sve značajke. Vrijednosti kontrolnih (traženih) varijabli nisu skalirane kako bi se izbjegao proces povratne transformacije vrijednosti u stvarne raspone, nakon što ih mreža reproducira.

Sljedeći korak je priprema matrica i nizova koji će služiti kao ulaz u mrežu.

Ulazni podaci za treniranje su preuređeni u 3D matricu oblika **(17352x24x5)**. Ove dimenzije predstavljaju 17 352 unosa, za 5 značajki, od kojih svaki unos ima svoju dodatnu dimenziju u kojoj se nalaze prošle 23 vrijednosti te iste značajke. Na isti je način uređen i set ulaznih podataka za testiranje, oblika **(168x24x5)**. Generalno možemo reći da ova mreža koristi ulazne podatke u obliku **(ukupni broj vremenskih koraka x broj relevantnih prošlih vrijednosti, „pogled unazad“ x broj značajki)**.

Kako bi set ulaznih podataka bio zadovoljavajući za konkretno odabrani prvi sloj ove mreže, potrebno je bilo nadodati još jednu sintetičku dimenziju, za konačni 4D oblik **ulaznih podataka**:

- podaci za treniranje oblika (17352x24x5x1)
- podaci za testiranje oblika (168x24x5x1)

Set izlaznih podataka predstavlja četiri tražene vrijednosti kontrolnih varijabli – krivulje punjenja i pražnjenja električne i toplinske pohrane. Za svaki vremenski korak, u kojem svaka ulazna značajka ima povijest svojih prošlih 23 vrijednosti, izlazni podatak modela je vrijednost kontrolnih varijabli u sljedećem vremenskom koraku, u sljedećem satu. Na taj način je uređen set **izlaznih podataka**:

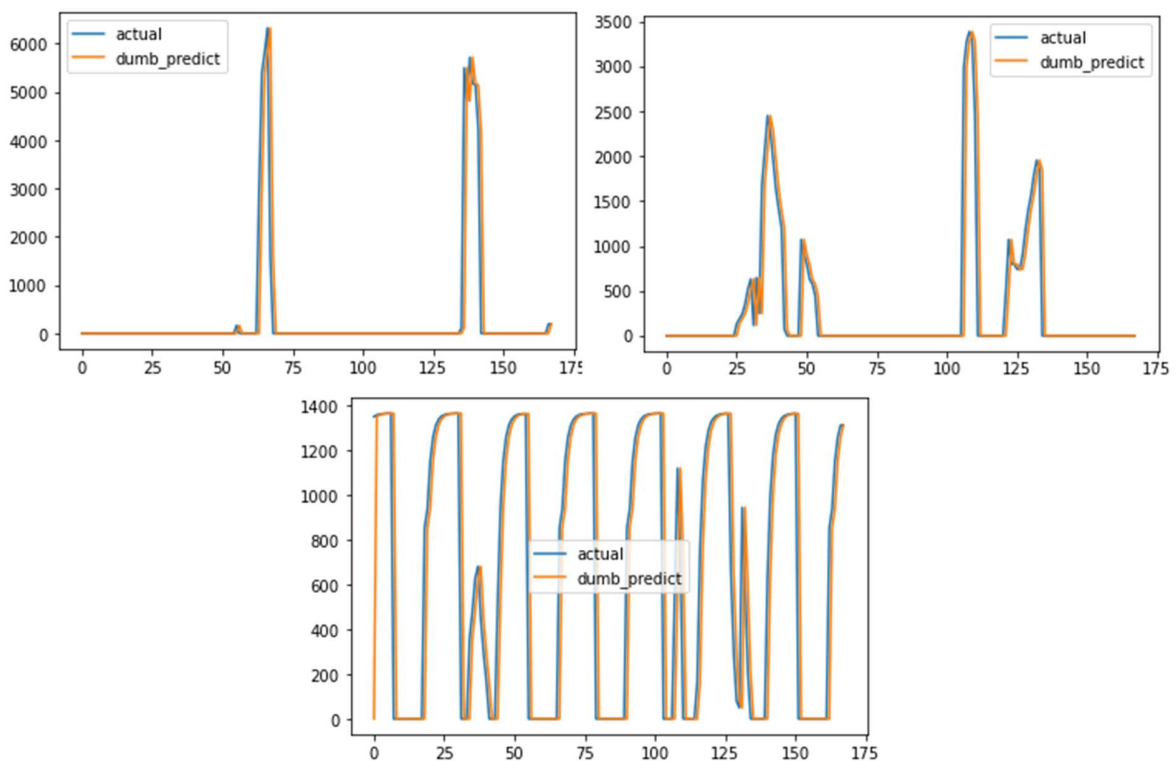
- podaci za treniranje oblika (17352x4)
- podaci za testiranje oblika (168x4)

3.2.3. Konstrukcija modela neuronske mreže

Zadatak samog modela je preuzeti ulazne podatke, transformirati ih kroz razne slojeve te na izlazu dobiti vrijednosti koje su jednake, u ovome slučaju, vrijednostima kontrolnih varijabli.

3.2.3.1. *Temeljni model za usporedbu*

Prvo je izrađen temeljni model (engl. baseline model) kako bi se usporedbom mogli ocijeniti daljnje konstruirani modeli. Ovaj model je veoma jednostavan, a temeljno načelo mu je da je vrijednost u prošlom satu dobar pokazatelj za sadašnju vrijednost, te ju tako i pretpostavi (slika 3-15).

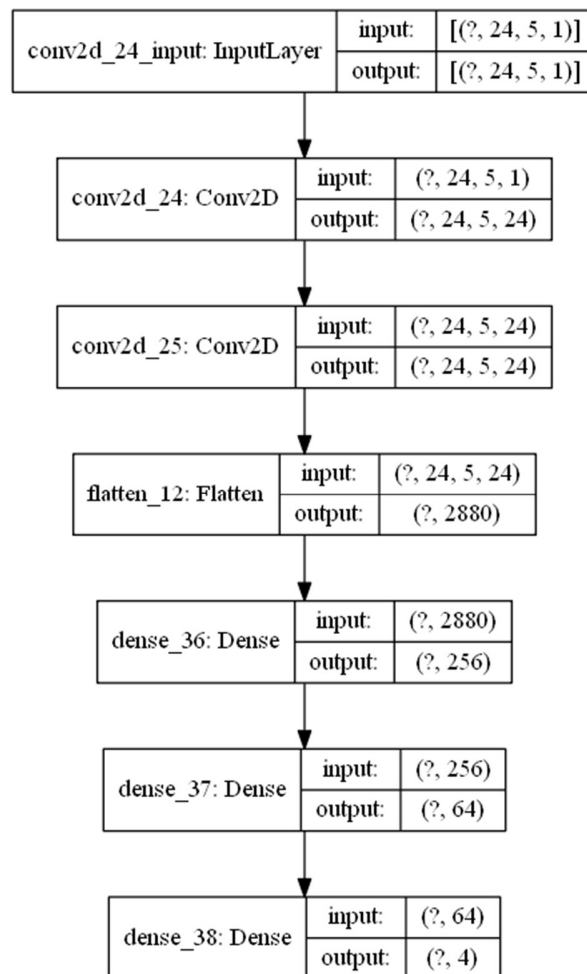


Slika 3-15. Grafovi traženih varijabli dobiveni temeljnim modelom

Prosječna ocjena (koeficijent određivanja, R^2 ocjena, R kvadrat) za točnost ove tri tražene varijable je 0,65, a korijen srednje kvadratne greške iznosi oko 400. To se može protumačiti da ovaj model, u prosjeku, konstantno griješi za 400kW.

3.2.3.2. Razvoj generalnog modela neuronske mreže u TensorFlow-u

Tipični izbor za ovaj tip problemskog zadatka bi bile LSTM i 1D konvolucijske strukture neuronske mreže, uz nadzirano učenje. No, zaključeno je kako su za ovu veličinu vremenskog slijeda i (relativno) veliki broj ulaznih varijabli, njihove mogućnosti ograničene. Naime, uvođenje dodatnih varijabli znatno usporava učenje i smanjuje kvalitetu konačnog rezultata. Iz tog razloga, za ovaj je zadatak odabrana topologija zasnovana na dvodimenzijskim konvolucijama (slika 1-2), sa dubinom od **pet** skrivenih slojeva.



Slika 3-16. Shema topologije konstruiranog modela

Generalno, konvolucija je matematička operacija koja izražava način na koji oblik jedne funkcije mijenja drugu. U ovome kontekstu, konvolucija predstavlja određeni broj filtera koji napreduju kroz 2D matricu ulaznih podataka. Koeficijenti filtera su pomnoženi sa vrijednostima originalne matrice te je produkt 2D matrica *filtriranih* vrijednosti, u ovom slučaju istih dimenzija, a naziva se karta značajki (engl. feature map) (slika 1-2.).

Broj i veličina filtera je definirana ulaznim argumentima u funkciju, a koeficijenti su naučeni iterativnim postupkom prilikom treniranja mreže. Na ovaj način, mreža uči izdvajati određene značajke i uzorke iz seta ulaznih podataka.

Transformacija ulaznih podataka započinje prvim 2D konvolucijskim slojem, a eksperimentalno odabrani parametri su:

- broj filtera = 24
- veličina filtera = 1x4

Sami sloj sadrži 120 parametra, odnosno koeficijenta za treniranje – četiri sadržana u konvolucijskom filteru + dodatna konstanta (engl. bias), za svaki od dvadeset i četiri filtera.

Izlazni oblik podataka iz ovog sloja je 4D tenzor dimenzija (*nedefinirano* x24x5x24). Prva dimenzija predstavlja broj uzoraka, u ovome slučaju broj vremenskih koraka seta za treniranje, te nije definirana, što znači da je mreža ravnodušna na broj ulaznih uzoraka, odnosno veličinu trenažne serije (engl. batch size). Zadnja dimenzija predstavlja broj filtera koji su korišteni u ovome sloju.

```

Model: "sequential_9"
-----
Layer (type)                Output Shape                Param #
-----
conv2d_18 (Conv2D)          (None, 24, 5, 24)          120
conv2d_19 (Conv2D)          (None, 24, 5, 24)          4632
flatten_9 (Flatten)         (None, 2880)                0
dense_27 (Dense)            (None, 256)                 737536
dense_28 (Dense)            (None, 64)                  16448
dense_29 (Dense)            (None, 4)                   260
-----
Total params: 758,996
Trainable params: 758,996
Non-trainable params: 0

```


Slika 3-17. Sažetak modela sa prikazanim odgovarajućim izlaznim oblicima svakoga sloja i brojem parametara.

Ovaj 4D tenzor služi dalje kao ulaz u idući sloj – druga 2D konvolucija.

Korišteni su isti parametri, osim veličine filtera oblika (8x1). Veličina osam koristi uzorke od 8 sati i u njima traži uzorke i značajke trendova promjene.

Istog je izlaznog oblika kao i prethodni sloj, (*nedefinirano* x24x5x24).

Kako bi daljnji slojevi klasičnih, u potpunosti spojenih, neurona mogli tumačiti informacije i *uvide* proslijeđene iz konvolucijskih slojeva, sljedeći korak je prolazak kroz sloj čiji je zadatak „spljoštiti“ (engl. flatten) ulazne podatke, odnosno dimenzijski ih reducirati na izlazni oblik (*nedefinirano* x2880). To znači da je 3D matrica podataka sekvencijski posložena u 1D vektor (24x5x24=2880) – slika 3-18. Ova funkcija nema ulaznih argumenata.



Slika 3-18. Primjer transformacije 2D matrice u 1D vektor (engl. flatten layer) (Saha, 2018)

Nakon toga slijede dva potpuno spojena sloja (engl. dense layer), prvi sa 256, a drugi sa 64 neurona. Svakome od prethodnih slojeva (osim sloju *flatten*) su nadodani regulatori utega i *pristranosti* (u vrijednosti od 0.001). Regulatorima se mrežu „kažnjava“ za prevelike vrijednosti utega te sprječava ikoji parametar da nauči previše. Na ovaj način, mreža ostaje balansirana te se pridonosi brzini učenja i smanjenju greške „pamćenja“ (engl. overfitting).

Posljednji sloj je također u potpunosti spojen, ali sa samo četiri neurona. Ova četiri neurona predstavljaju četiri tražene kontrolne varijable i vrijednost nakon njihove transformacije je tražena izlazna vrijednost. Iz tog razloga, u ovome slučaju je bilo potrebno eksplicitno definirati aktivacijsku funkciju. Iz ulaznog seta podataka možemo primijetiti da tražene, kontrolne varijable nemaju negativnih komponentni – sve vrijednosti su pozitivne, što predstavlja jednosmjerne energetske tokove, kako je i definirano. Pošto mreža za metriku gubitka koristi korijen srednje kvadratne pogreške, te joj je jedini i isključivi cilj da tu vrijednost smanji, činit će to i korištenjem negativnih vrijednosti varijabli. Unutar modela to može biti i dopušteno, ali pošto se na izlazu traže samo pozitivne vrijednosti, u zadnjem sloju koristimo ReLU (engl. rectified linear unit) aktivacijsku funkciju. ReLU funkcija je definirana kao pozitivni dio svog argumenta. Na taj način, sve negativne vrijednosti su odbačene – slika 1-4.

Naposljetku, pozvana je metoda *model.compile* kako bi se model konfigurirao za treniranje. Metoda koristi kao optimizator *Adam*, za mjerenje gubitka je korištena vrijednost srednje kvadratne greške, a za metriku napredovanja učenja vrijednost korijena srednje kvadratne greške. *Adam* je najčešće korištena klasa optimizatora stope učenja, a odlikuje ga brza i stabilna konvergencija zbog adaptivnih stopa učenja za svaki individualni parametar (Bashaev, 2018). Implementiran je sa zadanim postavkama; zadana stopa učenja je 0,001.

Sa time je završeno strukturiranje i konfiguracija modela, te je pozvana metoda *model.fit*. Ova se metoda koristi za treniranje samog modela, a za argumente koristi ulazni set podataka, izlazni (traženi) set podataka, broj epoha (iterativnih prolaza kroz set podataka), veličinu trenažne serije (engl. batch size) te eventualno dodatne objekte povratnog pozivanja (engl. callbacks), poput ranog zaustavljanja, povremenog spremanja najboljih utega, uvida u interno stanje modela tokom treniranja ili neke od osobno kreiranih objekata povratnog pozivanja. Broj epoha je određen kao 200 – eksperimentalno se određuje na temelju odnosa gubitka tokom učenja i valorizacijskog gubitka. Dokle god gubitak tokom učenja pada, ima smisla daljnje povećanje broja epoha, ali u trenutku kada on nastavi padati, a valorizacijski gubitak počne rasti treba zaustaviti učenje. To znači da je mreža počela predobro pamtit i prošle rezultate (engl. overfitting) te samo ponavlja „napamet“ ono što je vidjela, umjesto da prognozira sa „razumijevanjem“ situacije, odnosno komponenti izlaznog signala.

Za veličinu serije je odabrana veličina od 16.

Nakon što je model sastavljen i utreniran, pozivanjem metode *model.predict*, sa samo jednim argumentom – setom ulaznih podataka za testiranje, dobivaju se rezultati predikcije – prognoze budućih vrijednosti kontrolnih varijabli za sljedećih tjedan dana (168 sati).

3.3. ANALIZA REZULTATA

Konstruirani model pokazuje relativno stabilno učenje i konvergenciju rješenju. Definirane su sljedeće mjere gubitaka i ocjene izvedbe modela:


- *MSE*, srednja kvadratna greška (za trening, validacijski i test set)
- *RMSE*, korijen srednje kvadratne greške (za trening, validacijski i test set)
- *MAPE*, srednja apsolutna postotna greška (za trening, validacijski i test set)
- sličnost kosinusa (za trening, validacijski i test set)
- R^2 ocjena (za test set)

Tablica 3-1. Rezultati treniranja modela


	Trening set	Validacijski set	Test set
MSE	25 393	61 896	33 802
RMSE	159	248	183
MAPE	3 970 867 968	9 262 479 360	7 854 494 208
Sličnost kosinusa	0,7497	0,7693	0,6879
R^2 ocjena	-	-	0,936454

Model je pokazao najbolje rezultate u 197. epohi te je treniranje tu zaustavljeno. Trajanje iteracija tokom treninga je bilo 15ms/korak.

Ukupni gubitak modela je 25 393 odnosno 159kW. Validacijski gubitak je 61 896 – 248kW, slika 3-19. R^2 ocjena ovog modela za prognoziranje vrijednosti seta za testiranje je 0,936. U usporedbi sa temeljnim modelom čija je ocjena bila 0,65, ovaj model pokazuje znatno bolju izvedbu. Prilikom evaluacije modela na testu za testiranje dobiven je gubitak od 33 802, odnosno 183kW.




Slika 3-19. Gubitci tokom treniranja (trening i validacija)




Slika 3-20. Metrika „sličnosti kosinusa“ modela za vrijeme treniranja (trening i validacija)

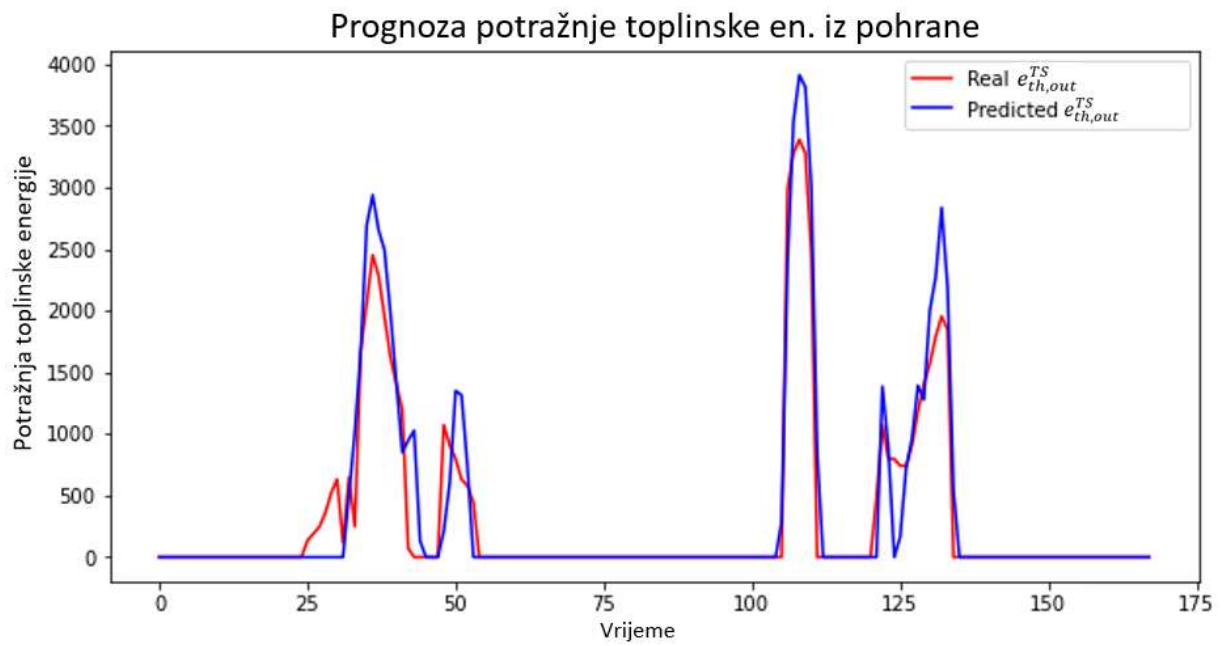
Iz grafova prognoze kontrolnih varijabli (slike 3-21. do 3-23.), vidljivo je kako **model pokazuje veliku nesigurnost i varijabilnost u trenucima vršnog opterećenja**, no veoma dobro procjenjuje promjene stanja i cikličnost **odnosno aktivaciju i deaktivaciju sustava**. To znači da bi konstruirani model teoretski mogao voditi mrežu, ali sa prosječnim odstupanjem od 6.4% od optimalnih vrijednosti.




Slika 3-21. Prognoza punjenja baterije BEV-a u trajanju od jednog tjedna



Slika 3-22. Prognoza punjenja toplinskog spremnika u trajanju od jednog tjedna



Slika 3-23. Prognoza pražnjenja toplinskog spremnika u trajanju od jednog tjedna



Slika 3-24. 24 filtera iz prvog konvolucijskog sloja (dimenzija 1x4)

Razmatranje o odstupanjima prognoziranih od stvarnih vrijednosti

Razlog ukupne greške može biti jer određena ulazna značajka nije pravilno procesuirana ili jer arhitektura modela nije dovoljno kompleksna.

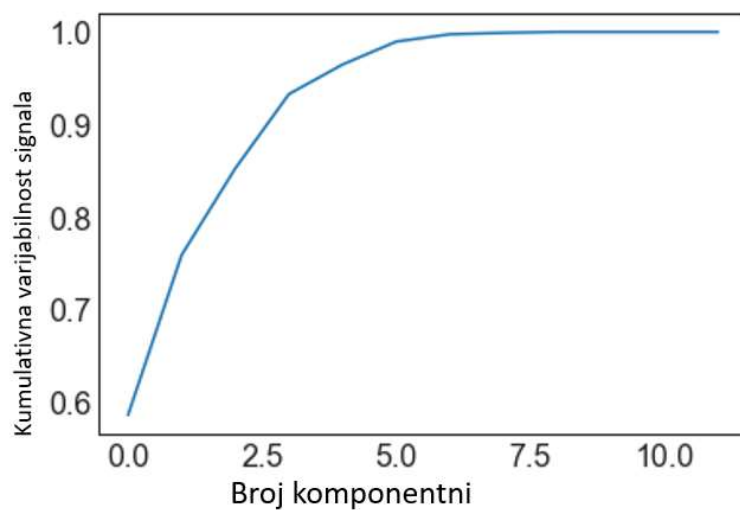
U drugu ruku, vrijednost razlike između gubitka pri treniranju te pri valorizaciji i testiranju, može ukazivati da model nije dovoljno utreniran. Potrebna je veća količina podataka ili bolje procesuiranje dostupnih podataka. *Pretjerano pamćenje* također može značiti da model ima previše parametara za treniranje. Ako nije dostupna dovoljna količina ulaznih podataka za treniranje svih parametara, trag vrijednosti slučajnosti inicijalizacije ostaje u vrijednostima parametra i time vodi ka krivim rezultatima. (Solegaonkar, 2019)

Smanjenjem broja ulaznih varijabli, model može biti jednostavniji i time manje sklon *pretjeranom pamćenju*. Algoritmi za izdvajanje značajki, poput PCA (engl. principal component analysis), pripomažu određivanju minimalnog seta značajki i na taj način omogućuju jednostavniji način za treniranje modela.

3.4. ANALIZA OSJETLJIVOSTI


PCA dekompozicija

Analiza glavnih komponenata (engl . principal component analysis, PCA) je postupak izračunavanja glavnih komponenata signala i njihove upotrebe za promjenu osnove na podacima, ponekad koristeći samo prvih nekoliko glavnih komponenti, a zanemarujući ostale (Milewski, 2017). Na ovaj način izdvajamo informacije koje su „dovoljno dobre“ da objasne podatke koje modeliramo. Navedeni proces se još naziva i smanjenje dimenzionalnosti.




Slika 3-25. PCA dekompozicija 12 odabranih ulaznih varijabli.

Iz grafa (slika 3-25.) je vidljivo da je kumulativna objašnjena varijansa seta ulaznih podataka visoka blizu pete komponente i dalje raste jako sporo. To znači da su informacije koje opisuju promjene većinom sadržane u 5 komponenti.



Slika 3-26. Korelacija 6 značajki dobivenih PCA dekompozicijom

Značajke dobivene PCA dekompozicijom ne pokazuju korelaciju.



Slika 3-27. Krivulje pet varijabli dobivenih PCA dekompozicijom

Na temelju generalnog modela, konstruiran je model sa dodanom *PCA* dekompozicijom seta ulaznih podataka te je time dobivena dodatna točnost i smanjeno je vrijeme treniranja. Ažurirani model je postigao točnost od $80kW(RMSE)$ i R^2 ocjenu 0,987, što je poboljšanje od otprilike 5%.

Tablica 3-2. Rezultati treniranja ažuriranog modela


	Trening set	Validacijski set	Test set
MSE	6 198	11 828	6 676
RMSE	77	107	80
MAPE	729 465 472	1 467 814 656	1 347 274 624
Sličnost kosinusa	0,7556	0,7872	0,6752
R^2 ocjena	-	-	0,98761

U ovome poglavlju, mijenjanjem veličine trenažne serije (engl. batch size) i dužine „pogleda unazad“, napravljena je analiza osjetljivosti modela na ova dva ulazna parametra. Navedene vrijednosti ocjena su izračunate za set za testiranje, u tablici 3-3.


Tablica 3-3. Analiza osjetljivosti modela

	Veličina trenazne serije (uzoraka)				
	4	32	64	128	16 (početna vrijednost)
MSE	8654	14 041	17 245	26 881	6 676
RMSE	91	118	131	163	80
MAPE	4802021888	12945456128	4024643072	7346340864	1347274624
Sličnost kosinusa	0,6783	0,6769	0,6782	0,6770	0,6752
R ² ocjena	0,98596	0,97747	0,96569	0,94751	0,98761
Vrijeme iteracije	11 ms/korak	17 ms/korak	23 ms/korak	34 ms/korak	14 ms/korak
	Dužina povijesnih unosa (sati)				
	8	48	72	168	24 (početna vrijednost)
MSE	40457	5156	6292	2943	6676
RMSE	201	70	77	51	80
MAPE	11452002304	1311444864	810536448	320589184	1347274624
Sličnost kosinusa	0,6812	0,6873	0,6812	0,6949	0,6752
R ² ocjena	0,92025	0,99102	0,98859	0,99591	0,98761
Vrijeme iteracije	4 ms/korak	23 ms/korak	37 ms/korak	101 ms/korak	14 ms/korak

Iz tablice 3-3. i provedene analize, može se zaključiti kako veličina trenazne serije svakako utječe na krajnji rezultat, a originalno izabrana veličina 16 se pokazala kao optimalna i u smislu kvalitete rješenja i u smislu brzine proračuna. **Sa pogledom od 168 sati unazad, ostvareni su daleko najbolji rezultati, uz R² ocjenu od 0,995 i odstupanjem od 51kW.** No, to je došlo pod cijenu od 5 sati treniranja.




Slika 3-28. Ovisnost rezultata o veličini trenažne serije




Slika 3-29. Ovisnost rezultata o veličini trenažne serije


U ovom modelu, manje je očita razlika rezultata između validacijskog i seta za treniranje te seta za testiranje – može se zaključiti da model manje pamti set za treniranje te bolje prognozira vrijednosti tokom testiranja. Slike 3-30. do 3-34. prikazuju rezultate postignute ovim modelom.




Slika 3-30. Gubitci tokom treniranja (trening i validacija)




Slika 3-31. Metrika „sličnosti kosinusa“ modela za vrijeme treniranja (trening i validacija)



Slika 3-32. Prognoza punjenja baterije BEV-a u trajanju od jednog tjedna



Slika 3-33. Prognoza punjenja toplinskog spremnika u trajanju od jednog tjedna



Slika 3-34. Prognoza pražnjenja toplinskog spremnika u trajanju od jednog tjedna

4. ZAKLJUČAK

Načelno je pokazano kako umjetna neuronska mreža zasnovana na 2D konvolucijskim strukturama ima kapacitet za razumijevanje, a time i vođenje, simuliranog energetskog sustava s visokom udjelom obnovljivih izvora energije.

Vremenska analiza i *PCA* dekompozicija se pokazala kao veoma koristan alat za komprimiranje informacija i uklanjanje šuma iz seta ulaznih podataka, te je time postavljen temelj za brže treniranje i točnije rezultate. Iako mreža pokazuje zadovoljavajuće rezultate, i dalje su očita značajna odstupanja i nesigurnost u trenutcima vršnih opterećenja. Zbog toga je potreban daljnji rad na optimizaciji ove arhitekture. To može uključivati i algoritme za mrežno pretraživanje hiperparametara poput broja slojeva, broja neurona, broja i veličine filtera, stope učenja, regularizacijske stope (za regulaciju utega i pristranosti) itd. Vremenska prognoza je još jedna ulazna varijabla, odnosno informacija, koja ima potencijal doprinijeti kvaliteti rezultata, no u ovom radu nije uzeta u obzir.

Povećanjem vremenske rezolucije (ispod jednog sata) i broja godina simulacije, moguće da bi se također doprinijelo smanjenju greške između predviđenih i stvarnih vrijednosti kontrolnih varijabli.

U ovome radu, problem je predstavljen kao zadatak nadziranog učenja. Značajne mogućnosti postoje u domeni potpomognutog učenja (engl. reinforcement learning), gdje mreža ima opciju da sama bilancira energetske tokove i traži optimalne odluke i politike, te kao i ova, koristi akumulirano znanje rasporeda (prirodnih zakonitosti i energetskih bilanci).

5. POPIS LITERATURE

1. Goodfellow, I., Bengio, Y., Courville, A., 2016. Deep Learning (Adaptive Computation and Machine Learning series). MIT Press, ISBN:978-0-262-03561-3. Cambridge, Massachusetts, SAD.
2. LeCun, Y., Haffner, P., Bottou, L., Bengio, Y. 1998. Object Recognition with Gradient-Based Learning. Red Bank, SAD: AT&T Shannon Lab.
3. Lee, G., Jung, S., 2019. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. Kyungpook National University, Gyeongsangbuk-do, Korea.
4. Singh, A., Sarkhel, R.; Kundu, M., Nasipuri, M. 2020. A Skip-Connected Multi-column Network for Isolated Handwritten Bangla Character and Digit Recognition. Sensing and Imaging. Article number: 28 (2020).
5. MZOiE, 2018. Energija u Hrvatskoj: godišnji energetska pregled. EIHP. Zagreb, RH.
6. Feng, J., 2019. Performance Analysis of Various Activation Functions in Artificial Neural Networks. Journal of Physics: Conference Series, Volume 1237.

- INTERNET IZVORI:

7. EK 2020. Renewable energy statistics, URL: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Renewable_energy_statistics (05.07.2021.)
8. EK, 2020. National Energy and Climate Plans: Member State contributions to the EU's 2030 climate ambition, URL: https://ec.europa.eu/commission/presscorner/detail/en/FS_20_1611 (28.06.2021.)
9. MGIPU, 2020. EK predlaže strategiju energetske obnove zgrada "Renovacijski val", URL: <https://mgipu.gov.hr/vijesti/ek-predlaze-strategiju-energetske-obnove-zgrada-renovacijski-val/11137> (28.06.2021.)
10. Kiverstein, J., 2019. 4. Is Perceptual Experience Controlled Hallucination?, URL: <https://philosophyofbrains.com/2019/06/19/4-is-perceptual-experience-controlled-hallucination.aspx> (01.07.2021.)
11. Brownlee, J., 2019. A Gentle Introduction to Generative Adversarial Networks (GANs), URL: <https://machinelearningmastery.com/what-are-generative-adversarial-networks-gans/> (29.6.2021.)

12. Sherstinsky, A. 2018., Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network, URL: <https://arxiv.org/abs/1808.03314> (29.06.2021.)
13. Lund, H., 2021. EnergyPLAN – Advanced analysis of smart energy systems, URL: <https://www.sciencedirect.com/science/article/pii/S2666955221000071?via%3Dihub> (22.6.2021.)
14. AI Wiki, 2021. Activation Function, URL: <https://docs.paperspace.com/machine-learning/wiki/activation-function> (28.6.2021.)
15. Bushaev, V., 2018. Adam - latest trends in deep learning optimization, URL: <https://towardsdatascience.com/adam-latest-trends-in-deep-learning-optimization-6be9a291375c> (28.06.2021.)
16. Saha, S., 2018. A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way, URL: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> (29.6.2021.)
17. Baeldung, 2020. What Are the Prerequisites for Studying Machine Learning?, URL: <https://www.baeldung.com/cs/machine-learning-how-to-start#2-general-systems-theory-and-cybernetics> (29.6.2021.)
18. Gao, B., Pavel, L., 2017. On the Properties of the Softmax Function with Application in Game Theory and Reinforcement Learning, URL: https://www.researchgate.net/publication/315834599_On_the_Properties_of_the_Softmax_Function_with_Application_in_Game_Theory_and_Reinforcement_Learning (29.06.2021.)
19. Milewski, P. 2017., PCA decomposition and Keras neural network, URL: <https://www.kaggle.com/pmmilewski/pca-decomposition-and-keras-neural-network> (02.07.2021.)
20. Solegaonkar, V. 2019., Error Analysis in Neural Networks, URL: <https://towardsdatascience.com/error-analysis-in-neural-networks-6b0785858845> (03.07.2021.)

IZJAVA

Izjavljujem da sam ovaj diplomski rad pod naslovom „Primjena umjetnih neuronskih mreža za potrebe vođenja energetskih sustava s visokim udjelom obnovljivih izvora energije“ izradio samostalno na temelju znanja stečenih na Rudarsko-geološko-naftnom fakultetu služeći se navedenom literaturom.



Filip Milešević



KLASA: 602-04/21-01/217
URBROJ: 251-70-12-21-2
U Zagrebu, 12.7.2021.

Filip Milešević, student

RJEŠENJE O ODOBRENJU TEME

Na temelju vašeg zahtjeva primljenog pod KLASOM 602-04/21-01/217, URBROJ: 251-70-12-21-1 od 1.7.2021. priopćujemo vam temu diplomskog rada koja glasi:

PRIMJENA UMJETNIH NEURONSKIH MREŽA ZA POTREBE VOĐENJA ENERGETSKIH SUSTAVA S VISOKIM UDJELOM OBNOVLJIVIH IZVORA ENERGIJE

Za voditelja ovog diplomskog rada imenuje se u smislu Pravilnika o izradi i obrani diplomskog rada Izv.prof.dr.sc. Luka Perković nastavnik Rudarsko-geološko-naftnog-fakulteta Sveučilišta u Zagrebu

Voditelj:

(potpis)

Izv.prof.dr.sc. Luka Perković

(titula, ime i prezime)

Predsjednik povjerenstva za
završne i diplomske ispite:

(potpis)

Izv.prof.dr.sc. Vladislav Brkić

(titula, ime i prezime)

Prodekan za nastavu i studente:

(potpis)

Izv.prof.dr.sc. Dalibor
Kuhinek

(titula, ime i prezime)