

Razporejanje električne energije v aktivnih distribucijskih omrežjih z uporabo kombiniranega optimizacijskega pristopa

Marko Corn^{1,2}, Gregor Černe¹, Igor Škrjanc², Maja Atanasijević-Kunc²

¹Inea d.o.o., Stegne 11, 1000 Ljubljana, Slovenija

²Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana, Slovenija

E-pošta: marko.corn@inea.si

Povzetek. V tem delu je predstavljen nov optimizacijski pristop razporejanja, ki omogoča hitre izračune z uporabo kombinacije nevronske mreže in lokalne optimizacije. Nevronska mreža je uporabljena za izračun rezultatov razporejanja, ki nato veljajo kot začetni pogoji pri uporabi lokalne optimizacije. Če se rezultati razporejanja, izračunanega z nevronske mreže, nahajajo relativno blizu optimalne rešitve, lokalna optimizacija hitro konvergira in še naprej izboljša dobljeni rezultat. Uspešna uporaba nevronske mreže je odvisna od kakovosti učne množice, ki mora vsebovati zelo dobre oz. skoraj optimalne rešitve. Učno množico pridobimo z uporabo genetskih algoritmov, pri katerih smo uporabljali številnejše generacije in večkratne ponovitve optimizacijskega postopka, vse v želji po pridobitvi dobrih rešitev. Pristop je bil testiran na primeru razporejanja energije v aktivnih distribucijskih elektroenergetskih omrežjih, kjer je treba uravnotežiti proizvodnjo in porabo električne energije. Simulacijski rezultati so pokazali, da pristop z uporabo kombinacije nevronske mreže in lokalne optimizacije v začetni fazi konvergira hitreje kot pristop z uporabo genetskih algoritmov. To pomeni, da je predstavljeni pristop primeren za uporabo tam, kjer so časi za izračun optimalne rešitve kratki.

Ključne besede: razporejanje, nevronske mreže, genetski algoritmi, aktivna distribucijska omrežja

Energy Scheduling in Smart Grids Using Combined Optimization Approach

The paper presents a new energy scheduling approach enabling fast calculation times with a combination of the neuron network and local optimization. A learned neuron network is used to calculate the energy scheduling results to be used as initial conditions for a local energy scheduling optimization method. When the scheduling results from a neuron network are located relatively close to the optimal solution, the local optimization method converges very fast and further improves the energy scheduling results. To calculate the energy scheduling results from a neuron network that are relatively close to the optimal solution, a learning dataset has to be generated containing nearly/optimal solutions. For this purpose, genetic algorithms are used with a large number of generations and several repetitions of the scheduling process. Our energy scheduling algorithm was tested using the electric energy flows in smart grids to balance the electric energy consumption and production. Simulation results prove that a combination of neuron network and local optimization converge faster than the genetic algorithm method but when the available time is very long, the genetic algorithms can sometimes provide better solutions. Following the above, the described method is useful when the times to calculate energy scheduling are short.

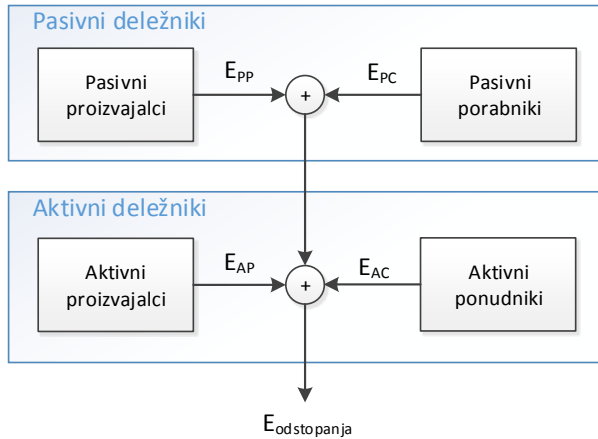
1 UVOD

Aktivna distribucijska omrežja (ang. smart grids) so elektroenergetska omrežja, ki inteligentno vključujejo vse priključene uporabnike v želji po zagotovitvi trajnostne, ekonomske ugodne in vedno razpoložljive električne energije [1]. Za doseg te ciljev je treba zagotoviti ravnovesje med električno porabo in proizvodnjo vseh priključenih uporabnikov. Optimizacija porabe in proizvodnje električne energije je ekonomski proces, saj proizvajalci prodajajo električno energijo porabnikom na trgu električne energije. Trg električne energije je razdeljen v bilančne skupine, ki povezujejo proizvajalce in porabnike v omrežju. Bilančna skupina je skupek merilnih mest (ki pomenijo posamezne proizvajalce oz. porabnike), prek katerih se izračunava ravnovesje, oz. bilanca med porabo in proizvodnjo električne energije.

1.1 Uporabljen model bilančne skupine

Model bilančne skupine, ki je shematično ilustriran na sliki 1, vključuje vse njene deležnike, ki pa jih lahko glede na način delovanja razdelimo v dve večji skupini: pasivne in aktivne deležnike [2]. Pasivni deležniki nimajo zmožnosti upravljanja porabe oz. proizvodnje električne energije. Pasivne deležnike naprej delimo v dve skupini: pasivne porabnike in pasivne proizvajalce. Pasivni porabniki so lahko gospodinjstva, industrija, poslovni objekti in drugi, ki porabljajo energijo po

lastnih potrebah. Pasivni proizvajalci pa so lahko vetrne, sončne in druge elektrarne, ki ne zmorejo prilagajanja proizvodnje električne energije, saj so meteorološko pogojeni.



Slika 1: Model bilančne skupine

Druga večja skupina so aktivni deležniki. To so vsi, ki imajo zmožnost prilagajanja proizvodnje oz. porabe električne energije. Tudi aktivne uporabnike delimo v dve skupini: na aktivne proizvajalce in aktivne ponudnike [3]. Aktivni proizvajalci so nuklearne elektrarne, termoelektarne na fosilna goriva, plinske elektrarne, hidroelektarne in drugi viri električne energije, ki lahko upravljajo proizvodnjo električne energije. S pojavom aktivnih distribucijskih omrežji pa so se pojavili tako imenovani aktivni ponudniki. Aktivni ponudniki so gospodinjstva oz. gospodinjstve, kot so pralni in pomivalni stroji, hladilniki, električni grelci, toplotne črpalke in druge naprave, katerim je mogoče prestaviti delovanje na poljubni čas v dnevu. Namesto da bi npr. oprali perilo ob treh popoldne, ga lahko tudi ob sedmih zvečer. Pri ogrevanju gospodinjstva s toplotno črpalko lahko zagon črpalke poljubno prestavimo za določen čas, vendar v mejah zmanjšane udobja, ki v tem primeru pomeni kratkotrajno znižanje temperature. Aktivni ponudniki so tudi industrijski objekti, kjer lahko z manipulacijo proizvodnje prav tako prestavljamo odjem električne energije. Med aktivne ponudnike pa z razvojem novih tehnologij shranjevanja električne energije lahko prištejemo tudi gorivne celice, električne avtomobile in druge naprave, ki so sposobne tako proizvodnje kot porabe električne energije na zahtevo. Pri aktivnih ponudnikih ne gre za zmanjševanje porabe električne energije, ampak za njeno prestavljanje v različne časovne termine. Energijsko ravnovesje bilančne skupine opisuje enačba (1):

$$\begin{aligned}
 & E_{PC}(k) + E^{-}_{AP}(k) \\
 & - E^{+}_{AP}(k) - E_{AC}(k) - E_{PP}(k) \\
 & = E_{ods}(k) = 0
 \end{aligned} \quad (1)$$

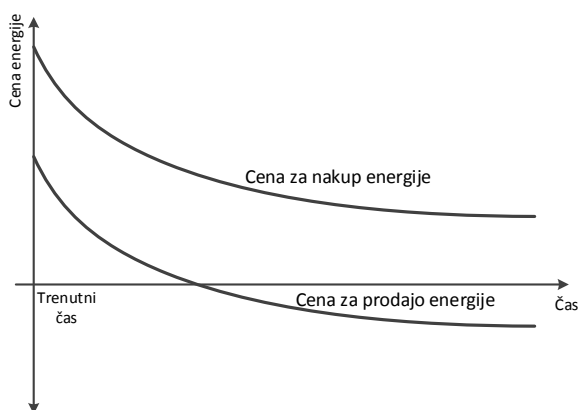
Poraba energije pasivnih porabnikov (E_{PC}) in poraba energije tistih aktivnih ponudnikov (E^{-}_{AC}), ki energijo trenutno porabljajo, mora biti enaka proizvodnji električne energije pasivnih proizvajalcev (E_{PP}), proizvodnji aktivnih proizvajalcev (E_{AP}) in proizvodnji tistih aktivnih ponudnikov, ki trenutno energijo proizvajajo (E^{+}_{AC}). Če proizvodnja ni enaka porabi, pride do odstopanj bilančne skupine (E_{ods}). Razdelitev uporabnikov bilančne skupine na pasivne in aktivne nakazuje, da lahko za zagotavljanje energijskega ravnovesja skrbijo samo aktivni uporabniki. Aktivna distribucijska omrežja omogočajo vključitev aktivnih ponudnikov v sistem zagotavljanja ravnovesja med porabo in proizvodnjo električne energije. Algoritem razporejanja optimizira delovanje aktivnih ponudnikov tako, da ti uspešno pripomorejo k zmanjševanju energijskih odstopanj bilančne skupine. Za lažje razumevanje vzrokov za potrebo hitrega algoritma razporejanja je treba razložiti proces zagotavljanja ravnovesja med proizvodnjo in porabo električne energije bilančne skupine.

1.2 Proces zagotavljanja energijskega ravnovesja

Proces izravnave med proizvodnjo in porabo električne energije se začne z napovedjo porabe ($E_{nap\ PC}$) oz. proizvodnje ($E_{nap\ PP}$) električne energije pasivnih uporabnikov bilančne skupine. Razlika obeh napovedi pomeni napovedana energijska odstopanja ($E_{nap\ ods}$), ki so zapisana z enačbo (2):

$$\begin{aligned}
 E_{nap\ ods}(l) &= E_{nap\ PP}(l) + E_{nap\ PC}(l) \\
 l &= 1 \dots m \\
 m & \dots \text{čas napovedovanja}
 \end{aligned} \quad (2)$$

Napovedana energijska odstopanja predstavljajo napoved energijskega neravnovesja, ki čaka bilančno skupino v primeru, da le-ta ne ukrepa. Bilančna skupina kupi energijo, s katero bo pokrila napovedana odstopanja, od aktivnih proizvajalcev. Energija, ki predstavlja predmet trgovanja na organiziranem trgu z električno energijo ima različne cene, ki so časovno odvisne. Večinoma je energija, ki se prodaja za prihodnje čase (npr. za 12 ur naprej od trenutnega realnega časa) cenejša kot energija, ki se prodaja za krajši čas vnaprej (npr. 1 uro naprej). Prav tako je energija lahko dražja ob tistem času, za katerega se pričakuje velika poraba (konična poraba). Primer poteka cen energije prikazuje slika 2. Na trgu sta ceni za prodajo in nakup električne energije različni. Obstajata dve vrsti cen za energijo: cena za prodajo in cena za nakup energije. Če imamo pozitivna napovedana odstopanja, to pomeni, da bomo imeli presežek energije in moramo na trgu to energijo prodati po ceni za prodajo energije. Nasprotno velja za negativna odstopanja. Algoritem razporejanja izračuna, koliko energije je treba kupiti na trgu, da izničimo napovedana odstopanja.



Slika 2: Cene energije na trgu z električno energijo v odvisnosti od časa

Hiter algoritem razporejanja ima dve prednosti. Prvič, lahko reagira na nenadne spremembe v napovedih pasivnih uporabnikov, ki nastanejo blizu trenutnega časa, in s hitrim izračunom pripomore k izravnavi teh sprememb (z uporabo aktivnih ponudnikov). Poleg tega pa hiter algoritem razporejanja lahko deluje v območju višjih cen energije na organiziranem trgu, saj se s hitrimi izračuni bistveno bolj približa trenutnemu času in s tem višjim cenam energije, kar posledično pomeni tudi višje zaslužke aktivnih ponudnikov.

1.3 Pregled področja algoritmov razporejanja

Večina algoritmov razporejanja se osredotoča na razporejanje računskih opravil po procesorjih za hitrejšo procesiranje ali pa razporejanje industrijskih oz. poslovnih procesov oz. sredstev za doseg učinkovitejših proizvodnje izdelkov oz. storitev. Obstaja veliko vrst algoritmov razporejanja. Omeniti je treba algoritme razporejanja, ki delujejo na podlagi seznamov, večstopenjske algoritme [4], podvojene algoritme, in druge. Vsi ti algoritmi se osredotočajo na razporejanje opravil, ki imajo natančno določen čas trajanja, ali količino porabljenih sredstev. Problem, s katerim se mora spopasti algoritem razporejanja v tem članku, pa je drugačne narave, saj je treba določiti ravno te parametre, ki so v prej opisanih algoritmi že določeni. Algoritmi, ki so uporabni za tovrstne probleme, so iterativne oz. lokalne optimizacijske metode, kot so npr. Newtonova metoda [5], konjugirano gradientna metoda [6], metoda gradientnega spusta [7], simpleks algoritem in druge. Ker pa so parametri optimizacije omejeni oz. so vezani na določena območja, imajo tovrstne metode težave pri iskanju optimalne rešitve. Večje možnosti pri iskanju dobrih rešitev imajo tako stohastične optimizacijske metode, kot so genetski algoritmi [8], diferencialna evolucija in podobne. Stohastične metode pogosto generirajo boljše rešitve, vendar pa je konvergenčni čas praviloma daljši.

V naslednjem razdelku je predstavljen nov pristop, ki omogoča hitro konvergenco in dobre rešitve pri

reševanju nakazanih problemov. Pristop združuje nevronske mreže in lokalno optimizacijsko metodo (NMLO). Na začetku naslednjega razdelka je opisan optimizacijski problem, kjer definiramo energijske pakete in sam optimizacijski proces. Nato pa je predstavljen tudi algoritem razporejanja NMLO. Njegova uspešnost je ilustrirana pri razporejanju na testnem primeru. Na koncu prispevka so predstavljeni rezultati testiranja, ki kažejo uspešnost opisanega pristopa v primerjavi z uporabo algoritma razporejanja na podlagi genetskih algoritmov.

2 OPTIMIZACIJSKI PROBLEM

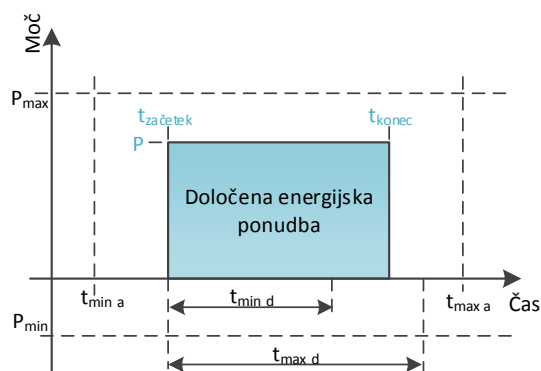
Algoritem razporejanja mora razpoložljive vire in porabo izravnati tako, da zmanjša energijska odstopanja bilančne skupine. Optimizacijski problem je razdeljen v dva dela: opis aktivnih ponudnikov, ki ponujajo energijo za izravnavo napovedanih odstopanj, in opis procesa energijske izravnave, ki poteka v bilančni skupini.

2.1 Aktivni ponudniki

Aktivni ponudniki imajo sposobnost prilagajanja porabe oz. proizvodnje električne energije. Ta sposobnost je zapakirana v energijsko ponudbo, ki je nato posredovana algoritmu razporejanja [9]. Energijsko ponudbo določa šest parametrov:

$$O_{ene} = \{t_{min a}, t_{max a}, t_{min d}, t_{max d}, P_{min}, P_{max}\} \quad (3)$$

Parametri energijske ponudbe opisujejo okno razpoložljivosti, okno trajanja in energijsko okno oz. okno razpoložljive moči (Slika 3).



Slika 3: Energijska ponudba

Okno razpoložljivosti ($t_{min a}$ in $t_{max a}$) in okno trajanja ($t_{min d}$ in $t_{max d}$) opisujeta časovno fleksibilnost ponudbe, medtem ko okno moči (P_{max} in P_{min}) opisuje njeno energijsko fleksibilnost po moči. Prek energijskih ponudb aktivni ponudniki sporočajo upravljavcu v bilančni skupini, koliko so pripravljene predstaviti svojo energijsko porabo oz. proizvodnjo, nato pa mora upravljavec s pomočjo algoritma razporejanja iz teh ponudb izračunati njihovo končno postavitev oz. jim

mora določiti njihov začetni ($t_{začetni}$) in končni (t_{konec}) čas ter moč (P). Enačba (4) opisuje določeno energijsko ponudbo:

$$O_{dolocena} = \{t_{zacetek}, t_{konec}, P\} \tag{4}$$

2.2 Proces izravnavanja napovedanih odstopanj

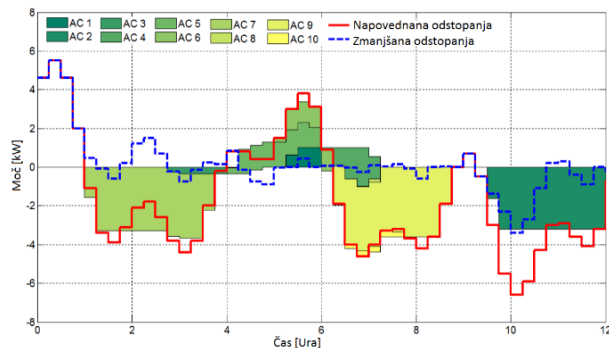
Izravnavanje energijskih odstopanj je razdeljeno v štiri korake (slika 4): 1.) izračun napovedanih odstopanj, 2.) zbiranje vseh energijskih ponudb vseh aktivnih ponudnikov, 3.) izračun razporejanja in 4.) nakup ali prodaja manjkajoče energije na trgu. V prvem koraku se izračunajo napovedi proizvodnje oz. porabe energije vseh pasivnih uporabnikov bilančne skupine. Ker samo napovedovanje presega obseg tega dela, so bili njegovi izračuni poenostavljeni na naključne vrednosti pozitivnih in negativnih odstopanj, tako da simulirajo prave napovedi. V drugem koraku se zberejo vse energijske ponudbe vseh aktivnih ponudnikov, ki so ponudbe pripravili, in se jih umesti v bazen ponudb, kjer ponudbe čakajo na določitev razporejanja, to pa se zgodi v naslednjem koraku.

Algoritem razporejanja izračuna razporeditev vseh ponudb v bazenu tako, da minimizira napovedna energijska odstopanja bilančne skupine. Kriterijsko funkcijo algoritma razporejanja določa enačba (5):

$$krit = \left| E_{napods} - \sum_{i=1}^n E_i(O_{i\ dolocena}) \right| \tag{5}$$

Kriterijska funkcija je enaka absolutni vrednosti razlike med energijo napovedanih odstopanj ($E_{nap\ ods}$) in vsoto energij posameznih določenih energijskih ponudb ($E_i(O_{i\ dolocena})$).

Slika 5 prikazuje primer napovedanih odstopanj (polna črta) ter desetih aktivnih ponudnikov, katerih energijske ponudbe je razporedil algoritem razporejanja ter z njimi zmanjšal napovedana odstopanja (črtkana črta).



Slika 5: Primer razporeditve energijskih ponudb

Zadnji korak procesa razporejanja je nakup manjkajoče energije na trgu. Če je malo ponudb, namenjenih za razporejanje, algoritem razporejanja ne more izničiti oz.

kompensirati vseh napovedanih odstopanj, zato je treba manjkajočo energijo kupiti na organiziranem trgu električne energije od aktivnih proizvajalcev. Na primeru s slike 5 je to energija, ki je potrebna, da izniči črtkano črto. Količina energije, ki jo je treba kupiti na trgu, je tako odvisna od števila in primernosti energijskih ponudb aktivnih ponudnikov. V primeru na sliki 5 vidimo, da je večina napovedanih odstopanj pokrita z uporabo aktivnih ponudnikov.


3 RAZPOREJANJE Z UPORABO NEVRONSKE MREŽE IN LOKALNE OPTIMIZACIJE

Uporabljeni algoritem razporejanja temelji na kombinaciji nevronske mreže in lokalne optimizacije, pri čemer izkorišča relativne prednosti obeh pristopov.

3.1 Nevronska mreža

Nevronske mreže je tudi mogoče učinkovito uporabljati pri reševanju kompleksnih problemov vodenja [10, 11], ki so lahko zvezne, diskretne ali hibridne narave, vključujejo pa lahko tudi nelinearnosti. Zato smo se odločili, da preizkusimo njihovo učinkovitost tudi pri reševanju problemov energijskega odstopanja predstavljena sistema. Nevronska mreža je prva stopnja izračuna razporejanja in jo uporabimo kot preslikavo iz energijskih ponudb in energijskih odstopanj v določene energijske ponudbe oz. z uporabo nevronske mreže direktno izračunamo rezultat razporejanja (slika 6).

Vhodni podatki oz. vhodi v nevronske mreže so parametri vseh energijskih ponudb ($O_{ene\ 1}, \dots, O_{ene\ n}$), ki se nahajajo v bazenu in vrednosti časovnega poteka napovedanih odstopanj ($E_{ods\ 1}, \dots, E_{ods\ m}$). Njeni izhodi ($O_{dolocena\ 1}, \dots, O_{dolocena\ n}$) pa določajo razporeditev (vhodnih) energijskih ponudb tako, da minimizirajo (vhodna) napovedana energijska odstopanja. Za uporabo je treba nevronske mreže prej naučiti pravilnega obnašanja. To pomeni, da moramo nevronske mreže naučiti, da za vsako kombinacijo energijskih ponudb in energijskih odstopanj izračuna oz. določi razporeditev energijskih ponudb tako, da bo vrednost kriterijske funkcije minimalna. Za uspešno učenje nevronske mreže potrebujemo veliko učenjskih podatkov (po izkušnjah mora biti učna množica vsaj 5000-kratnik števila vhodov v nevronske mreže), saj je število mogočih kombinacij ponudb in odstopanj velikansko.



Slika 6: Primer razporeditve energijskih ponudb

Učna množica za ta primer je bila pridobljena z uporabo genetskih algoritmov (GA), ki so se izkazali za uspešne pri izračunih razporejanj. Generiranje učne množice je potekalo tako, da smo najprej generirali energijske ponudbe in napovedna energijska odstopanja, nato pa izračunali razporejanje s pomočjo GA.

3.2 Lokalna optimizacija

Nevronska mreža je uporabljena za izračun določitve energijskih ponudb. Ker je nevrnska mreža v svojem bistvu nelinearni aproksimator, se njene rešitve ob predpostavki, da je nevrnska mreža dovolj dobro naučena, nahajajo relativno blizu globalnega minimuma, oz. blizu neke dobre rešitve. To rešitev naprej optimiziramo z uporabo lokalne optimizacijske metode, katere rešitev konvergira izjemno hitro, saj se začetni parametri nahajajo blizu optimalne rešitve.

V nadaljevanju so predstavljeni rezultati algoritma NMLO, ki ga primerjamo z algoritmom razporejanja, izvedenega z GA (enak algoritem kot smo ga uporabili pri generiranju učne množice).

4 REZULTATI SIMULACIJ

Simulacije so bile izvedene s programom Matlab, ker ponuja preprost razvoj algoritmov in vključuje veliko orodij za pomoč pri različnih vidikih modeliranja, optimizacije in simulacije. Testno okolje definira:

- 10 aktivnih ponudnikov, vsak od njih ponuja maksimalno
- 20kWh energije.

Napovedana odstopanja se izračunavajo za

- 12 ur vnaprej s
- 15-minutno resolucijo in
- maksimalnim odstopanjem ± 10 kW električne moči.

Nevronska mreža je tipa perceptron ("feedforward" v Matlabu) z:

- 109 vhodi (60 parametrov energijskih ponudb in 49 podatkov o napovedanih odstopanjih),
- 30 izhodi (30 parametrov določenih energijskih ponudb desetih aktivnih ponudnikov),
- vhodnim nivojem, ki sestoji iz 100 nevronov,
- enim skritim nivojem, ki sestoji iz 100 nevronov in
- 30 izhodnih nevronov.

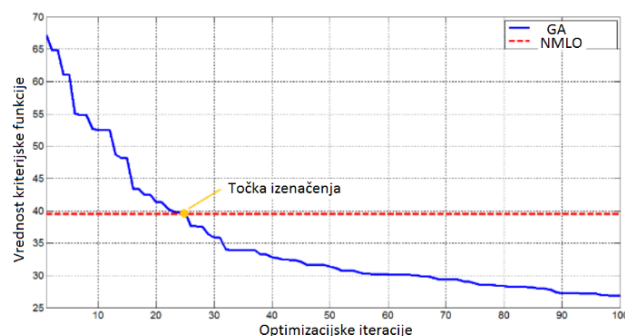
Uporabljen je bil algoritem vzratnega učenja na podlagi

- 509800 parov učne množice.

Učna množica je bila generirana z GA iz Matlabovega orodja Global optimization. Nelder-Mead Simplex Method je bila uporabljena kot lokalna optimizacijska metoda (uporabili smo torej funkcijo *fminsearch* v Matlabu).


Rezultate učinkovitosti algoritma NMLO v primerjavi z GA prikazuje slika 7. NMLO algoritem

konvergira v enem iteracijskem trenutku GA, saj se izračun nevrnske mreže zgodi v enem koraku, konvergenca lokalne optimizacije pa je, zahvaljujoč dobrim začetnim pogojem (ki jih generira nevrnska mreža), izjemno hitra in prav tako ne potrebuje več kot en iteracijski trenutek GA. V primerjavi s konvergenco algoritma razporejanja, izvedenega z GA, je na začetku optimizacije boljši, vendar samo do določene točke (točka izenačenja). Od tam naprej GA še izboljšuje rezultat. Za hiter algoritem razporejanja so pomembni samo rezultati pred to točko oz. rezultati majhnega števila iteracij, ki v tem primeru pomenijo tudi čas, potreben za konvergenco.



Slika 7: Primerjava konvergence NMLO in genetskih algoritmov

Za boljše vrednotenje algoritma smo naredili tudi statistični test NMLO z več izračuni razporejanja ter opazovali točko izenačenja. Rezultate testa prestavlja slika 8, ki prikazuje porazdelitev točk izenačenja 1000 izračunov razporejanja. Slika 8 prikazuje distribucijo točk izenačitve glede na število iteracij algoritma razporejanja, izvedenega z GA.



Slika 8: Porazdelitev točk izenačenja po izračunu 1000 razporejanj

V večini primerov je bil algoritem NMLO boljši od GA do 15. iteracije, nato pa njegova uspešnost pada, kar kaže, da bo algoritem NMLO najpogosteje izračunal boljšo rešitev kot GA do njegove 15. iteracije. Ti

rezultati veljajo pri pogoju, da imamo v bilančni skupini 10 aktivnih ponudnikov in napovedujemo za 12 ur vnaprej z resolucijo $\frac{1}{4}$ ure.

5 SKLEP

V članku je predstavljen hiter algoritem razporejanja, ki uporablja kombinacijo nevronske mreže in lokalne optimizacije (NMLO) na primeru razporejanja energije v aktivnih distribucijskih omrežjih. Algoritem omogoča hitrejše odzivanje predstavljenega sistema aktivnega distribucijskega omrežja na motnje in uporabnikom omrežja omogoča večji zaslužek oz. prihranek.

NMLO ima to prednost, da lahko izračuna rezultate bistveno hitreje, kot je to mogoče z genetskimi algoritmi. Kakovost rezultatov je odvisna od kvalitete naučenosti nevronske mreže, ki pa jo lahko še dodatno izboljšamo z uporabo večje učne množice, ali pa same konfiguracije nevronske mreže. Vendar ima v tem pogledu NMLO eno omejitev. Ker je bila učna množica izračunana z genetskimi algoritmi, NMLO ne more generirati rezultatov, boljših od naučenih. Če bi želeli doseči tudi to, bi morali uporabiti drugačen pristop k učenju nevronske mreže, kjer bi se učenje nevronske mreže izvajalo po načelih evolucije z naključnimi spremembami sinaps oz. uteži povezav. Nakazano možnost bomo vsekakor raziskali v prihodnosti.

LITERATURA

- [1] J. Momoh "Smart Grid: Fundamentals of Design and Analysis", New Jersey, John Wiley & Sons, 2012.
- [2] M. Corn, G. Černe, and M. Atanasijević-Kunc, "Optimizacija pretokov električne energije v aktivnih distribucijskih omrežjih z uporabo nevronske mreže in lokalne optimizacije", 22. mednarodna elektrotehniška in računalniška konferenca ERK 2013, 16.–19. 9. 2013, Portorož.
- [3] M. Corn, G. Černe, and M. Atanasijević-Kunc, "Balance Group Model with Smart Grid Elements", 7. mednarodna konferenca o matematičnem modeliranju MathMod 2012, Duna.j
- [4] F. Kato and S. Shin, "Multistep optimal scheduling of Automated Guided Vehicles," mednarodna konferenca SICE, 2010, strani 985–989.
- [5] S. Kim, J. Y. Lee, D. K. Sung, S. Member, A. Generalized, J. Shaw and R. Gendron, "Bandwidth allocation for fluid input generalized processor sharing servers," IEEE Transactions on Communications, vol. 58, no. 5, pp. 1514–1523, 2010.
- [6] C. Y. Chan, J. Y. B. Lee, and M. Hamdi, "Gradient-descent scheduler", ICC 2005, IEEE International Conference on Communications, 2005, vol. 1, no. C, pp. 389–395 Vol. 1.
- [7] H. Qiu, W. Zhou, and H. Wang, "A Genetic Algorithm-Based Approach to Flexible Job-Shop Scheduling Problem," in Natural Computation, 2009. ICNC '09. Fifth International Conference on, 2009, vol. 4, pp. 81–85.

- [8] R. Storn and K. Price, "Differential Evolution – A Simple and Efficient Heuristic," Journal of Global Optimization, vol. 11, pp. 341–359, 1997.
- [9] Z. Marinšek and G. Černe, "Roles and processes model for electricity market trading processes in Europe," Proc. 6th International Workshop on Deregulated Electricity Market Issues in South-Eastern Europe, September 2009, pp. 1–7.
- [10] B. Potočnik, G. Mušič, I. Škrjanc, and B. Zupančič, "Model-based Predictive Control of Hybrid Systems: A Probabilistic Neural-network Approach to Real-time Control," Journal of Intelligent and Robotic Systems, vol. 51, no. 1, pp. 45–63, Sep. 2007.
- [11] Glavan, M., D. Gradišar, S. Strmčnik, G. Mušič. "Production modelling for holistic production control", Simulation modelling practice and theory, Vol. 30, pp. 1–20, 2013

Marko Corn je leta 2010 diplomiral iz elektrotehnike v Ljubljani. Zaposlen je v podjetju Inea, d.o.o., od leta 2010 kot aplikativni inženir in raziskovalec, kjer dela na področju energetike. Njegovo raziskovalno delo sega na področje optimizacije, evlucijskih algoritmov, modeliranja in simulacije.

Dr. Gregor Černe je diplomiral iz fizike na Fakulteti za Matematiko in fiziko ter nato doktoriral na IJS, na Odseku za jedrsko tehniko. V podjetju Inea, d.o.o., je od leta 2008 kot vodja projektov zaposlen v poslovni enoti za energetiko, kjer dela na aktivnih omrežjih, vodenju elektroenergetskih sistemov in sistemov za meritve ter nadzor energentov.

Dr. Igor Škrjanc je diplomiral leta 1988, magistriral 1991. in doktoriral 1996. na Fakulteti za elektrotehniko Univerze v Ljubljani. Zdaj je zaposlen kot redni profesor na Fakulteti za elektrotehniko Univerze v Ljubljani. Njegova pedagoška in raziskovalna dejavnost je usmerjena na področje adaptivnih, prediktivnih, mehko logičnih in mehko logično adaptivnih sistemov vodenja.

Dr. Maja Atanasijević-Kunc je diplomirala leta 1981, magistrirala leta 1984 in doktorirala leta 1997 na Fakulteti za elektrotehniko Univerze v Ljubljani. Zdaj je zaposlena kot izredna profesorica na Fakulteti za elektrotehniko Univerze v Ljubljani. Njena pedagoška in raziskovalna dejavnost je usmerjena na področje modeliranja, simuliranja in vodenja dinamičnih, kompleksnih sistemov.