

Određivanje optimalne raspodele tokova snaga pomoću modifikovanog genetskog algoritma

Darko Šošić

Energetika/Katedra za elektroenergetske sisteme
Univerzitet u Beogradu Elektrotehnički fakultet
Beograd, Srbija
sosisic@etf.rs

Jelena Stojković

Student osnovnih studija
Univerzitet u Beogradu Elektrotehnički fakultet
Beograd, Srbija
jelena.stojkovic11710@gmail.com

Sadržaj—Optimalna raspodela tokova snaga je veoma primenjena u sektoru upravljanja elektroenergetskog sistema kao i u planerskom sektoru. U deregulisanoj elektroenergetskoj sistemu, od velike je važnosti rešavanje ovog problema, zbog određivanja cene električne energije kao i zbog rešavanja problema zagađenja elektroenergetskog sistema. Posmatrani problem ima ne-monotonu oblast rešenja, tako da klasične metode koje jako zavise od početnog pogađanja konvergiraju u lokalni optimum ili divergiraju. U radu je korišćen modifikovani genetski algoritam za nalaženje optimalne raspodele tokova snaga, a za verifikaciju algoritma su korišćene dva standardna test sistema, IEEE 30 i IEEE 24 RTS.

Ključne riječi—optimalni tokovi snaga; modifikovani genetski algoritam; minimizacija troškova proizvodnje; proračun tokova snaga; prenosni sistem

I. UVOD

Cilj proračuna optimalnih tokova snaga je promalaženje optimalne kombinacije proizvodnje električne energije iz pojedinih generatora, amplitude napona sabirnice, i izbora otepa regulacionih transformatora koji mogu da menjaju položaj pod opterećenjem a sve u cilju minimizacije troškova proizvodnje termalnih jedinica, ukupne emisije gasova, i ukupnih gubitaka aktivne snage uz zadovoljenje fizičkih i tehničkih ograničenja mreže. Rešavanju ovog problema dosta pažnje je posvećeno u sektoru planiranja, upravljanja i kontrole elektroenergetskim sistemom.

Optimizacija raspodele tokova snaga optimizuje objektivnu funkciju zadovoljavajući pri tom razna ograničenja tipa jednakosti i nejednakosti. U prošlosti su korišćene konvencionalne metode za rešavanje problema optimalne raspodele tokova snaga. Generalno gledano, većina klasičnih optimizacionih tehnika primenjuje analizu osjetljivosti i algoritme zasnovane na nalaženju gradijenta optimizacione funkcije pri tom linearizujući tu objektivnu funkciju i razmatrana ograničenja u okolini radne tačke. Nažalost, problem nalaženja optimalne raspodele tokova snaga je veoma nelinearan optimizacioni problem, odnosno, postoji više od jednog lokalnog optimuma. Tako da, tehnike koje se zasnivaju na lokalnoj optimizaciji, a koje su dobro razrađene, nisu pogodne za ovakve probleme. Štaviše, ne postoji kriterijum koji odlučuje da li je lokalno rešenje ujedno i globalno rešenje. Stoga, konvencionalne metode optimizacije koje koriste izvode

i gradijente nemaju mogućnost identifikacije globalnog optimuma.

Ovaj optimizacioni problem generalno gledano ima nekonveksnu, prekidnu, nediferencijabilnu objektivnu funkciju. Tako da je postalo neophodno razviti optimizacione tehnike koje su efikasne u prevazilaženju ovih nedostataka i rešavanju zadatih problema. U poslednje vreme, metode evolucionarnog programiranja su uzele sve više udela u rešavanju problema raspodele tokova snaga.

Evolucionarni algoritam, čiji je jedan predstavnik i genetski algoritam, se razlikuje od klasičnih metoda pretrage i optimizacije [1] u mnogo čemu. Klasične metode pretrage koriste unapređenje jednog rešenja u svakoj iteraciji, i uglavnom koriste determinističke metode približavanja optimalnom rešenju. Takvi algoritmi polaze iz proizvoljno izabrane tačke, i na osnovu nekog unapred određenog pravca kretanja, algoritam sugerise pravac pretrage na osnovu lokalnih informacija. Koriste pretragu u jednom smeru u cilju nalaženja najboljeg rešenja. Sa druge strane evolucionarni algoritmi rade sa skupom potencijalnih rešenja, koja se porede međusobno po vrednosti svoje *fitness* funkcije. Kod evolucionarnih metoda pretraga prosotora rešenja se zasniva na heurističkim metodama, stoga pretraga nije nikad samo u jednom smaru. Cilj svih evolucionarnih metoda je pravljenje boljeg skupa potencijalnih rešenja u svakoj narednoj iteraciji.

U [2] za rešavanje problema je korišćen evolucionarni algoritam sa dvostrukim postupkom inicijalizacije i izbačena je operacija mutacije. Višekriterijumska optimizacija za rešavanje problema optimalne raspodele snaga je korišćena u [3]. Razmatrani kriterijumi su smanjenje proizvodnih troškova, i ukupnih gubitaka u sistemu, kao i uravnoteženje amplituda napona u mreži. Nakon rešavanja svakog pojedinačnog optimizacionog problema konačno rešenje je izabrano pomoću kombinacije PSO i fuzzy tehnike. U [4], [5] je pomoću fuzzy pristupa rešen problem raspodele tokova snaga uvažavajući i nesigurnosti sa kojima se sreću operatori prenosnog sistema usled nepreciznih podataka, a koji su posledica odstupanja od prognozirane vrednosti. Skoro razvijena metoda diferencijalne evolucije je primenjena u [6] za rešavanje razmatranog problema.

U [7] je korišćen efikasni evolucionarni algoritam za rešavanje razmatranog problema. Ovaj algoritam koristi model

inkrementalnog povećanja toka snage i matrice osetljivosti radi smanjenja broja proračuna tokova snaga. Prvo su nalažena pojedinačna optimalna rešenja za sledeće slučajeve: smanjenje troškova proizvodnje, smanjenje gubitaka u sistemu i uravnoteženje naponskih prilika. Nakon toga optimalno rešenje je birano pomoću SPEA 2+ [8] tehnike koja se primenjuje kod višekriterijumske optimizacije.

Metod modifikovane diferencijalne evolucije je korišćen u [9] za rešavanje raspodele tokova snaga kada su za troškove proizvodnje korišćene prekidne i nekonveksne funkcije. Pomoću iste metode u [10] rešen je problem hidrotermalne raspodele snaga za posmatrani period.

Rad je organizovan na sledeći način: u drugom delu prikazan je optimizacioni problem. Opis modifikovanog genetskog algoritma i predloženi algoritam su prikazani u poglavljima tri i četiri. Rezultati primene predloženog algoritma su prikazani u petom delu. Dok je u šestom delu dat zaključak rada.

II. OPTIMIZACIONI PROBLEM

Rešenje problema optimalne raspodele tokova snaga za cilj ima optimizaciju objektivne funkcije pomoću optimalnih podešenja kontrolnih promenljivih elektroenergetskog sistema uz zadovoljenje ograničenja tipa jednakosti i nejednakosti. Matematički, problem optimalne raspodele snaga se može prikazati u sledećoj formi:

$$\begin{aligned} \text{Min } J(x,u) & \quad (1) \\ \text{U zavisnosti od: } g(x,u) &= 0 \quad (2) \\ h(x,u) &\leq 0 \quad (3) \end{aligned}$$

gde je J objektivna funkcija koju treba minimizovati, a x je vektor zavisnih (sistemskih) promenljivih koji se sastoji od:

- Proizvodnje aktivne snage iz referentnog čvora P_{SL} .
- Amplituda napon na sabirnicama potrošačkog tipa V_L .
- Proizvodnja reaktivne snage generatora Q_G .
- Tokovi snaga po vodovima S_l .

Tako da se x može predstaviti kao:

$$x^T = [P_{SL}, V_{L1} \dots V_{LNL}, Q_{G1} \dots Q_{GNG}, S_{l1} \dots S_{lnl}] \quad (4)$$

gde su NL , NG , nl broj potrošačkih sabirnica, broj generatora, i broj prenosnih vodova u posmatranom elektroenergetskom sistemu, respektivno.

„ u “ je vektor nezavisnih (kontrolnih) promenljivih koji se sastoji od:

- Proizvodnje aktivne snage u čvorovima PV tipa P_G .
- Amplituda napon na generatorskim sabirnicama V_G .
- Podešavanje odcepa regulacionog transformatora T_r .
- Proizvodnja reaktivne snage iz kompenzatora Q_C .

Tako da se u može predstaviti kao:

$$u^T = [P_{G2} \dots P_{GNG}, V_{G1} \dots V_{GNG}, T_{r1} \dots T_{rNT}, Q_{C1} \dots Q_{CNC}] \quad (5)$$

gde su NT i N_C broj regulacionih transformatora i broj kompenzatora reaktivne snage, respektivno.

„ g “ su ograničenja tipa jednakosti, koja najčešće predstavljaju jednačine tokova snaga:

$$P_{Gi} - P_{Di} - V_i \sum_{k=1}^{NB} V_k [G_{ik} \cos(\theta_i - \theta_k) + B_{ik} \sin(\theta_i - \theta_k)] \quad (6)$$

$$Q_{Gi} - Q_{Di} - V_i \sum_{k=1}^{NB} V_k [G_{ik} \sin(\theta_i - \theta_k) - B_{ik} \cos(\theta_i - \theta_k)] \quad (7)$$

gde je NB broj čvorova, P_G je proizvodnja aktivne snage generatora, Q_G je proizvodnja reaktivne snage generatora, P_D je potrošnja aktivne snage, Q_D je potrošnja reaktivne snage, G_{ik} i B_{ik} su konduktansa i susceptansa između čvorova i i k , respektivno.

„ h “ predstavlja ograničenja tipa nejednakosti koja uvažavaju:

- Ograničenja generatora: amplituda napona, proizvodnja aktivne i reaktivne snage je ograničena donjom i gornjom granicom:

$$V_{Gi}^{\min} \leq V_{Gi} \leq V_{Gi}^{\max}, i = 1, \dots, NG \quad (8)$$

$$P_{Gi}^{\min} \leq P_{Gi} \leq P_{Gi}^{\max}, i = 1, \dots, NG \quad (9)$$

$$Q_{Gi}^{\min} \leq Q_{Gi} \leq Q_{Gi}^{\max}, i = 1, \dots, NG. \quad (10)$$

- Ograničenja transformatora: izbor odcepa je ograničen donjim i gornjim položajem:

$$T_i^{\min} \leq T_i \leq T_i^{\max}, i = 1, \dots, NT. \quad (11)$$

- Ograničenja kompenzatora reaktivne snage:

$$Q_{Ci}^{\min} \leq Q_{Ci} \leq Q_{Ci}^{\max}, i = 1, \dots, N_C. \quad (12)$$

- Sigurnosna ograničenja: uvažavaju ograničenja po amplitudi napona na potrošačkim sabirnicama i termička ograničenja vodova:

$$V_{Li}^{\min} \leq V_{Li} \leq V_{Li}^{\max}, i = 1, \dots, NL \quad (1)$$

$$S_{li} \leq S_{li}^{\max}, i = 1, \dots, nl. \quad (1)$$

III. GENETSKI ALGORITAM

Genetski algoritam oponaša prirodne evolucionarne procese u cilju formiranja metoda pretrage i optimizacionih procedura. U stvarnosti, genetski algoritam se razlikuje od klasičnih metoda pretrage i optimizacionih procedura na više načina. Genetski algoritam ima posebnu prednost u odnosu na konvencionalne metode optimizacije jer mu nije potreban

striktni matematički model objektivne funkcije [11]. Glavna prednost genetskog algoritma je rad sa populacijom rešenja u okviru svake iteracije, dok konvencionalne optimizacione metode rade samo sa jednim rešenjem, slika 1. Upravo zbog ove činjenice genetski algoritam konvergira ka globalnom optimumu, dok konvencionalne metode kao što su tehnike nelinearnog programiranja mogu konvergirati u lokalni optimum usled izbora loše polazne tačke. Otuda se zbog navedenih činjenica bira genetski algoritam kada je potrebno rešiti neki optimizacioni problem vezan za elektroenergetski sistem kada god je to moguće. Pored svega navedenog lakoća i jednostavnost programiranja genetskog algoritma dovodi ga u sam vrh prilikom izbora optimizacione metode.

Ovo je metod slučajnog pretraživanja koji se može koristiti za rešavanje nelinearnih sistema jednačina kao i za optimizaciju složenih problema. Princip ovog algoritma se zasniva na izboru jedinki. Ne zahteva se dobra početna procena zarad dobijanja dobrog rešenja. Drugim rečima, rešenje složenog problema se može dobiti i iz loše početne procene, a koja će obradom u genetskom algoritmu dati dobro rešenje.

Standardni genetski algoritam je napravljen za rad sa binarnim nizovima. Svaki od pomenutih nizova predstavlja moguće rešenje razmatranog problema. Ovako predstavljeno potencijalno rešenje, binarni niz, se drugačije naziva hromozom. Već je pomenuto da genetski algoritam radi sa većim brojem rešenja, taj broj (N) se definiše pre početka rešavanja problema, i ceo taj skup se naziva populacija. Unutar jedne generacije (iteracije), potrebno je izračunati vrednosti *fitness* funkcije svakog hromozoma pošto se dalji rad sa operatorima genetskog algoritma vezuje upravo za vrednost *fitness* funkcije. Tri osnovna operatora genetskog algoritma (elitizam, ukrštanje i mutacija) se primenjuju na selektovane hromozome iz trenutne generacije u nadi stvaranja boljeg naraštaja. Danas postoje dve vrste kodiranja promenljivih u genetskom algoritmu [12]: binarno i decimalno kodiranje. Autori su se u ovom radu odlučili za konvencionalno binarno kodiranje promenljivih.

A. Kodiranje


Kod binarnog kodiranja svaka promenljiva se predstavlja binarnim nizom fiksne dužine. Na primer, sledeći niz predstavlja problem sa n promenljivih:

$$\underbrace{11011}_{x_1} \underbrace{01001110}_{x_2} \underbrace{010}_{x_3} \dots \underbrace{1001}_{x_n}$$

i -ta promenljiva je kodirana binarnim nizom dužine l_i , što znači da je ukupni broj vrednosti koje ova promenljiva može uzeti 2^{l_i} . Donja granica x_{min} je predstavljena binarnim nizom (00...0), dok je gornja granica x_{max} predstavljena sledećim binarnim nizom (11...1). Sve druge kombinacije niza s_i se dekodiraju na sledeći način:

$$x_i = x_i^{\min} + \frac{x_i^{\max} - x_i^{\min}}{2^{l_i} - 1} DV(s_i) \quad (15)$$

gde je $DV(s_i)$ dekodirana vrednost niza. Dekodirana vrednost



Slika 1. Proces nalaženja rešenja pomoću GA i konvencionalnog algoritma

podniza $S = (S_{l-1} S_{l-2} \dots S_2 S_1 S_0)$ je:

$$DV(S) = \sum_{j=0}^l 2^j S_j. \quad (16)$$

Ukupna dužina jednog hromozoma je određena dužinama svih podnizova, tj. jednaka je njihovoj sumi.

B. Fitness funkcija

Kada su posle procesa dekodiranja, koji je opisan u prethodnom koraku, dobijene vrednosti svih promenljivih moguće je izračunati vrednost optimizacione funkcije $f(x_1, \dots, x_n)$. Svakom hromozomu, bilo da je on nastao kao posledica operatora genetskog algoritma ili u početnoj populaciji, se mora odrediti vrednost *fitness* funkcije koja je povezana sa vrednošću optimizacione funkcije razmatranog hromozoma. Kod optimizacionih problema kod kojih se traži maksimum, vrednosti *fitness* funkcije hromozoma se izjednačavaju sa vrednostima optimizacione funkcije istih. Dok se kod problema minimizacije koristi sledeći pristup:

$$Fitness = \frac{1}{1 + f(x_1, \dots, x_n)}. \quad (17)$$

C. Selekcija

Selekcija je jedan od prvih operatora klasičnog genetskog algoritma koji se primenjuje na populaciji. Pomoću selekcije se formira baza jedinki nad kojima će se izvršavati drugi operatori. U ovom radu umesto formiranja baze jedinki, selekcija je korišćena za izbor hromozoma kada god je to bilo potrebno. Postoje brojni načini selekcije, od kojih će u ovom radu biti opisane samo upotrebljavane metode. Prva korišćena metoda je metoda točka ruleta, kod koje se koristi verovatnoća izbora određenog hromozoma. Verovatnoća izbora i -tog hromozoma je $f_i / \sum_{j=1}^N f_j$, gde je N veličina populacije, a f_i vrednost *fitness* funkcije i -tog hromozoma. Širina polja na točku ruleta koji zauzima i -ti hromozom zavisi od njegove verovatnoće. Ovo znači da ako hromozom ima veliku vrednost *fitness* funkcije zauzimaće veći deo točka, i obrnuto ako je

vrednost *fitness* funkcije mala deo na točku koji je dodeljen ovom hromozomu biće mali. Mana ovog izbora je što lošiji hromozomi skoro da nemaju nikakve šanse da budu izabrani [13]. Druga metoda selekcije je metoda rangiranja. Kod ove metode hromozomi se rangiraju prema vrednosti *fitness* funkcije, tj. hromozom sa najboljom vrednošću *fitness* funkcije dobija rang *N* dok najgori hromozom dobija rang 1. Treća metoda je metoda turnira, kod koje se proizvoljno uzimaju dva hromozoma iz trenutne populacije. Hromozom sa boljom vrednošću *fitness* funkcije prolazi selekciju i nad njime se obavljaju druge operacije genetskog algoritma. Ove metode su izabrane zbog svojih dobrih karakteristika i da bi se pokrile loše karakteristike svake pojedinačne metode. U ovom radu je korišćena sledeća procentualna raspodela po metodama selekcije: točak ruleta 45%, rangiranje 45% i turnir 10%.

D. Elitizam

U ovom radu operacija elitizma se prva primenjuje nad populacijom. Pomoću nje se unapred definisan broj hromozoma sa najboljom vrednošću *fitness* funkcije kopira direktno u novu populaciju. Pomoću ove operacije se izbegava gubitak dobrih rešenja i rapidno se ubrzava genetski algoritam.

E. Ukrštanje

Operator ukrštanja je zadužen za pretragu u genetskom algoritmu, i primenjuje se odmah posle elitizma. U literaturi postoje brojne metode ukrštanja, dok će se u ovom radu opisati samo primenjene metode. Prvo je neophodno izabrati učesnike u operaciji ukrštanja na neki od gore navedenih načina. U zavisnosti od izbora ukrštanja potrebno je odrediti mesta ukrštanja, a nakon toga pomešati hromosome koji su izabrani za roditelje i dobiti potomke. Jednostruko ukrštanje unutar podniza obezbeđuje širu pretragu prostora u kome se nalazi rešenje, međutim ova metoda lako uništava nizove koji u sebi mogu da sadrže informacije o optimalnom rešenju. Jednostruko i dvostruko ukrštanje iako ne mogu da pretražuju celokupan prostor rešenja imaju daleko manju verovatnoću uništavanja već pronađenih optimalnih delova niza. Na sledećim primerima biće prikazana primena korišćenih operatora ukrštanja (i i j predstavljaju proizvoljno odabrana mesta ukrštanja).

Hromozom 1 **10110|01101**
Hromozom 2 01101|11010

Potomak 1 **1011011010**
Potomak 2 0110111010

Hromozom 1 **101|10011|01**
Hromozom 2 011|01110|10

Potomak 1 **1010111001**
Potomak 2 011**1001110**

Hromozom 1 **1:01|10:0|11:01**
Hromozom 2 0:11|01:1|10:10

Potomak 1 **1111011110**
Potomak 2 **0010101001**

U ovom radu raspodela vrsta ukrštanja je urađena na sledeći način: jednostruko ukrštanje 65%, dvostruko ukrštanje 25% i jednostruko ukrštanje unutar podniza 10%.

F. Mutacija

Mutacija se koristi radi sprečavanja konvergencije svih rešenja prema jednom optimumu. U početnim iteracijama sprečava algoritam od konvergencije ka lokalnom minimumu, a u kasnijim iteracijama kada se sva rešenja približe optimalnom ova operacija nema preveliki značaj. Ona predstavlja proizvoljnu promenu bita odabranog hromozoma, sa podjednakom verovatnoćom promene svih bitova u nizu. Ograničavanje broja bitova nad kojima je dozvoljena operacija mutacije [14] ima svoje prednosti u odnosu na fiksnu raspodelu bita koji se mogu mutirati [15].

IV. PREDLOŽENI ALGORITAM

1. Priprema baze podataka za generatore, vodove, transformatore, sabirnice i šant elemente.
2. Zadavanje inicijalnih parametara genetskog algoritma: veličina populacije (*N*), maksimalan broj generacija (*T*), definisanje broja hromozoma nad kojima će se vršiti neka od operacija genetskog algoritma, definisanje procentualne raspodele za metode selekcije, definisanje procentualne raspodele za vrste ukrštanja.
3. Određivanje broja bitova kojima se predstavljaju promenljive pomoću sledećeg izraza:

$$2^{zah_bit_i-1} < (Pg_i^{\max} - Pg_i^{\min}) \cdot prec \leq 2^{zah_bit_i} \quad (18)$$

gde je $prec=10^{\text{broj decimalnih mesta zahtevane preciznosti}}$.

4. Određivanje ukupnog broja bita jednog hromozoma

$$\text{Ukupan broj bita} = \sum_{i=1}^{Ng} zah_bit_i \quad i \neq slack \quad (19)$$

5. Proizvoljno generisati hromozom početne populacije. Pomoću jednačina (15) i (16) dekodirati vrednosti proizvodnje generatora.
6. Pustiti proračun tokova snaga. U ovom radu za proračun tokova snaga korišćena je Newton-Raphson metoda.
7. Ako je dostignuto neko od ograničenja (ograničenje po amplitudi i faznom stavu napona sabirnica, aktivna i reaktivna snaga proizvodnje generatora, tok prividne snage po vodu) takav hromozom se odbacuje i vraća se na korak 5. Ovom procedurom izbegnut je rad sa penalizacionim faktorima pošto će svi članovi početne populacije biti izvodljivi.
8. Ponoviti postupak od koraka 5 do koraka 7 dok se ne popuni cela početna populacija.
9. Izračunati i sačuvati troškove proizvodnje za sve hromosome razmatrane populacije.
10. Izračunati vrednost *fitness* funkcije za svaki hromozom prema izrazu (17).

11. Iz trenutne populacije direktno prebaciti unapred određeni broj hromozoma sa najboljom vrednošću *fitness* funkcije u novu populaciju operacijom elitizma.
12. Izabrati roditelje za operaciju ukrštanja nekom od gore pomenutih metoda. U zavisnosti od izabrane metode ukrštanja proizvoljno izabrati potreban broj tačaka ukrštanja. Za dobijene potomke odraditi proračun tokova snaga. Proveriti da li potomci zadovoljavaju definisane kriterijume, kao što je definisano u koraku 7. Ako potomci ne narušavaju nijedno ograničenje upisuju se u novu populaciju, u suprotnom se odbacuju i vraća se na početak ovog koraka. Procedura opisana u ovom koraku se ponavlja sve dok se ne dostigne broj hromozoma koji je definisan za operaciju ukrštanja.
13. Nekom od metoda selekcije izabrati hromozom nad kojim će se izvršiti operacija mutacije. Izabrati bit koji će se mutirati. Za dobijenog potomka pustiti proračun tokova snaga. Proveriti da li su zadovoljeni svi definisani kriterijumi, kao što je definisano u koraku 7. Ako nije narušeno nijedno ograničenje upisati novonastali hromozom u novu populaciju, u suprotnom ga treba odbaciti. Odrediti nad koliko će se hromozoma vršiti operacija mutacije u sledećoj iteraciji pomoću sledeće zakonitosti [16]:

$$n_mut = N_mut \left(1 - r^{(1-t/T)^b} \right) \quad (20)$$

gde je n_mut broj hromozoma trenutne populacije nad kojima se izvršava operacija mutacije, N_mut je broj hromozoma prve iteracije nad kojim se izvršava operacija mutacije, r je proizvoljan broj između 0 i 1 (u našem slučaju $r = 0,2$), t je broj trenutne iteracije, T je maksimalan broj iteracija, b je sistemski parametar koji određuje stepen zavisnosti od broja iteracija (u našem slučaju $b = 2$). Odrediti novi broj hromozoma nad kojima će se izvršiti operacija ukrštanja u narednoj iteraciji.

14. Nova populacija postaje trenutna populacija.
15. Povećati brojač generacija (iteracija) *gen_brojac* za 1. Ako je $gen_brojac < T$, ide se na korak 9. U suprotnom iz trenutne populacije pronaći najbolju jedinku i prikazati rezultat.

U tabeli I su dati parametri koji su značajni za predloženi algoritam. Početne stope ukrštanja i mutacije, date u tabeli I, govore o tome koliki će biti procentualni udeo svake od ovih operacija u generisanju potomaka nove populacije. U kasnijim iteracijama ovi odnosi se menjaju.

V. REZULTATI

Predloženi algoritam je primenjen na dve standardne mreže, IEEE 30 sistem [17], i IEEE 24 sistem [18], [19]. Svi problemi su rešavani pomoću koda koji je razvijen u MATLAB-u na Pentium dual-core 2,1 GHz računaru. Optimalna raspodela snaga u oba primera je vršena po kriterijumu minimalnih troškova proizvodnje. Za kontrolne promenljive odabrane su

TABELA I. KONTROLNI PARAMETRI

Kontrolni parametri	Definicija
$N = 50$	Veličina populacije
$T = 100$	Maksimalan broj generacija
$el_rate = 0,1$	Stopa elitizma
$cros_rate = 0,7$	Početna stopa ukrštanja
$mut_rate = 0,2$	Početna stopa mutacije

samo snage proizvodnje generatora.


U prvom primeru, razmatrana je mreža IEEE 30, u proizvodnim čvorovima se nalazi po jedan generator i troškovi proizvodnje su dati kvadratnom funkcijom. Podaci o troškovima proizvodnje pojedinih generatora dati su u tabeli II.

Radi poredjenja na slici 2 su prikazane konvergencije predloženog algoritma i klasičnog genetskog algoritma. Sa slike se može videti da zbog naprednijeg načina pretrage, uvedene operacije elitizma i više načina odabira jedinki predloženi algoritam brže nalazi optimalno rešenje. U tabeli III su radi poredjenja dati rezultati oba algoritma. Pošto se sa slike 2 može zaključiti da predloženi algoritam brže konvergira, što znači da mu se može smanjiti maksimalan broj iteracija. Ako mu se smanji maksimalan broj iteracija na 40, vreme nalaženja optimalnog rešenja se smanjuje za 50% i iznosi 162,04 s. Sa slike se može videti da usled nedostatka operacije elitizma dolazi do povremenog gubitka dobrih rešenja i do pogoršavanja celokupne populacije. Tako da bi u slučaju korišćenja zaustavnog kriterijuma koji se bazira na udaljenosti najboljeg rešenja u trenutnoj populaciji od vrednosti medijana *fitness* funkcije posmatrane populacije, došlo bi do bržeg zaustavljanja ali i do skupljeg rešenja, što je pokazano u tabeli IV. Rešenja u tabeli IV su postignuta posle 21 iteracija za primenu klasičnog genetskog algoritma, odnosno posle 18 za predloženi algoritam.

Za drugi primer je uzeta mreža IEEE 24, kod koje u pojedinim čvorovima postoji više različitih tipova generatora. Predloženi algoritam ne koristi agregisanje svih generatora u posmatranom čvoru u jedan generator već svaki generator gleda posebno. Na osnovu [19] autori su izračunali koeficijente kvadratne funkcije troškova proizvodnje datih generatora, i ti koeficijenti su prikazani u tabeli V.

TABELA II. KOEFICIJENTI TROŠKOVA PROIZVODNJE GENERATORA U MREŽI IEEE 30

Broj čvora	Koeficijenti troškova proizvodnje generatora		
	$a(\$/h)$	$b(\$/MWh)$	$c(\$/MW^2h)$
1	0	2,00	0,00375
2	0	1,75	0,01750
5	0	1,00	0,06250
8	0	3,25	0,00834
11	0	3,00	0,02500
13	0	3,00	0,02500



Slika 2. Konvergencija običnog genetskog algoritma i predloženog algoritma

TABELA III. REZULTATI PREDLOŽENOG ALGORITMA I KLASIČNOG GENETSKOG ALGORITMA

	GA ^a	MGA ^b		GA ^a	MGA ^b
P_{G1} (MW)	175,94	177,37	P_{G11} (MW)	12,22	12,49
P_{G2} (MW)	48,36	48,12	P_{G13} (MW)	12,00	12,00
P_{G5} (MW)	23,75	21,67	Troškovi (\$)	807,59	807,30
P_{G8} (MW)	21,85	22,62	Vreme(s)	392,90	353,07

a. Klasičan genetski algoritam
b. Modifikovani genetski algoritam

TABELA IV. REZULTATI SA ZAUSTAVNIM KRITERIJUMOM

	GA	MGA		GA	MGA
P_{G1} (MW)	176,95	173,94	P_{G11} (MW)	15,08	13,66
P_{G2} (MW)	51,13	50,74	P_{G13} (MW)	14,40	12,24
P_{G5} (MW)	20,71	22,03	Troš. (\$)	808,23	807,49
P_{G8} (MW)	16,20	21,53	Vreme(s)	87,89	63,34

TABELA V. KOEFICIJENTI TROŠKOVA PROIZVODNJE

Generator		Koeficijenti troškova proizvodnje generatora		
P_{min} (MW)	P_{max} (MW)	a (\$/h)	b (\$/MWh)	c (\$/MW ² h)
2,4	12	69,1131	-4,4693	0,297200000
15,8	20	-7,8152	7,0925	-0,11810000
15,2	76	37,4459	-0,4350	0,004532000
25	100	54,1230	-0,2806	0,001986000
54,25	155	26,4794	-0,07473	0,000329033
68,95	197	47,0462	-0,06263	0,000245790
140	350	23,7535	-0,01590	0,000040398
100	400	14,4666	-0,01819	0,000028219

U tabeli VI su prikazani rezultati predloženog algoritma sa i bez korišćenja kriterijuma zaustavljanja.

TABELA VI. REZULTATI PREDLOŽENE METODE ZA MREŽU IEEE 24

	MGA-S ^a	MGA ^b		MGA-S ^a	MGA ^b
P_{G1-20} (MW)	16,32	16,03	P_{G15-12} (MW)	8,69	8,60
P_{G1-20} (MW)	15,91	15,87	$P_{G15-155}$ (MW)	146,75	137,64
P_{G1-76} (MW)	50,40	62,54	$P_{G16-155}$ (MW)	143,40	143,30
P_{G1-76} (MW)	70,85	44,13	$P_{G18-400}$ (MW)	533,05	343,91
P_{G2-20} (MW)	15,90	15,80	$P_{G21-400}$ (MW)	349,24	374,83
P_{G2-20} (MW)	16,49	16,06	P_{G22-50} (MW)	21,47	48,80
P_{G2-76} (MW)	44,16	41,67	P_{G22-50} (MW)	28,11	27,00
P_{G2-76} (MW)	45,58	39,29	P_{G22-50} (MW)	29,53	20,11
P_{G7-100} (MW)	48,74	81,57	P_{G22-50} (MW)	25,73	18,51
P_{G7-100} (MW)	87,44	64,74	P_{G22-50} (MW)	45,07	45,48
P_{G7-100} (MW)	89,28	68,27	P_{G22-50} (MW)	34,42	44,47
$P_{G13-197}$ (MW)	176,61	187,57	$P_{G23-155}$ (MW)	101,66	134,33
$P_{G13-197}$ (MW)	176,61	187,57	$P_{G23-155}$ (MW)	142,53	130,70
$P_{G13-197}$ (MW)	176,61	187,571	$P_{G23-350}$ (MW)	349,39	304,34
P_{G15-12} (MW)	7,65	7,68	Troškovi (\$)	1342,33	1336,50
P_{G15-12} (MW)	8,53	7,13	Vreme(s)	125,12	517,90
P_{G15-12} (MW)	5,47	6,97	Iteracija	21	100
P_{G15-12} (MW)	6,45	7,24			

a. Modifikovani genetski algoritam sa metodom usrednjavanja
b. Modifikovani genetski algoritam

VI. ZAKLJUČAK

U radu je predstavljen modifikovani genetski algoritam pomoću kojeg je rešavan problem optimalne raspodele tokova snaga. U odnosu na klasičan genetski algoritam uvedena je i operacija elitizma koja sprečava gubitak dobrih rešenja i na taj način značajno ubrzava konvergenciju algoritma. Za izbor jedinki korišćena su tri metode u cilju izbegavanja loših osobina pojedinačnih metoda. Pored klasične metode ukrštanja u jednoj tački uvedene su još dve metode koje omogućavaju pretragu šireg prostora rešenja. Kriterijum minimizacije troškova proizvodnje je korišćen pri rešavanju problema optimalne raspodele tokova snaga, pri čemu su uvažavana sva relevantna ograničenja tipa jednakosti i nejednakosti. Predložena metoda je testirana na dve standardne mreže, IEEE 24 i IEEE 30.

ZAHVALNICA

Autori zahvaljuju Ministarstvu za nauku i tehnološki razvoj Republike Srbije koje je omogućilo izradu ovog rada u okviru Projekta III 42009 Inteligentne energetske mreže.

LITERATURA

- [1] K. Deb, and D. Kalyanmoy, Multi-Objective Optimization Using Evolutionary Algorithms, New York, John Wiley & Sons, 2001.
- [2] A.V. Naresh Babu, T. Ramana, and S. Sivanagaraju, "Analysis of optimal power flow problem based on two stage initialization

- algorithm,” *International Journal of Electrical Power & Energy Systems*, vol. 55, pp. 91-99, 2014.
- [3] M. S. Kumari and S. Maheswarapu, “Enhanced Genetic Algorithm based computation technique for multi-objective Optimal Power Flow solution,” *International Journal of Electrical Power & Energy Systems*, vol. 32, pp. 736-742, 2010.
- [4] R.-H. Liang, S.-R. Tsai, Y.-T. Chen, and W.-T. Tseng, “Optimal power flow by a fuzzy based hybrid particle swarm optimization approach,” *Electric Power Systems Research*, vol. 81, pp. 1466-1474, 2011.
- [5] A. Mohapatra, P. R. Bijwe, and B. K. Panigrahi, “Optimal Power Flow with Multiple Data Uncertainties,” *Electric Power Systems Research*, vol. 95, pp. 160-167, 2013.
- [6] A. A. Abou El Ela, M. A. Abido, and S. R. Spea, “Optimal power flow using differential evolution algorithm,” *Electric Power Systems Research*, vol. 80, pp. 878-885, 2010.
- [7] S. Surender Reddy, P. R. Bijwe, and A. R. Abhyankar, “Faster evolutionary algorithm based optimal power flow using incremental variables,” *International Journal of Electrical Power & Energy Systems*, vol. 54, pp. 198-210, 2014.
- [8] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, “A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II,” *IEEE Transactions on Evolutionary Computation*, vol. 6, pp. 182-197, 2002.
- [9] S. Sayah and K. Zehar, “Modified differential evolution algorithm for optimal power flow with non-smooth cost functions,” *Energy Conversion and Management*, vol. 49, pp. 3036-3042, 2008.
- [10] L. Lakshminarasimman and S. Subramanian, “A modified hybrid differential evolution for short-term scheduling of hydrothermal power systems with cascaded reservoirs,” *Energy Conversion and Management*, vol. 49, pp. 2513-2521, 2008.
- [11] V. Miranda, J. V. Ranito, and L. M. Pmença, “Genetic algorithms in optimal multistage distribution network planning,” *IEEE Transactions on Power Systems*, vol. 9, p. 7, 1994.
- [12] Z. Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*, Berlin, Springer, 1996.
- [13] M. Younes, M. Rahli, L. and A. Koridak, “Economic power dispatch using evolutionary algorithm,” *Journal of Electrical Engineering*, vol. 57, pp. 211-217, 2006.
- [14] D. Šošić and I. Škokljek, “Evolutionary Algorithm for Calculating Available Transfer Capability,” *Journal of Electrical Engineering - Elektrotechnicky Casopis*, vol. 64, pp. 291-297, 2013.
- [15] J. Radosavljević, D. Klimenta, and M. Jevtić, “Steady-State Analysis of Parallel-Operated Self-Excited Induction Generators Supplying an Unbalanced Load,” *Journal of Electrical Engineering - Elektrotechnicky Casopis*, vol. 63, pp. 213-223, 2012.
- [16] D. Šošić and I. Škokljek, “Doprinos rešavanju problema zauzeća kapaciteta za prenos,” presented at the 31. savetovanje CIGRE Srbija, Zlatibor, 2013.
- [17] Y. R. Sood, “Evolutionary programming based optimal power flow and its validation for deregulated power system analysis,” *International Journal of Electrical Power & Energy Systems*, vol. 29, pp. 65-75, 2007.
- [18] Reliability Test System Task Force, “IEEE Reliability test system,” *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-98, pp. 2047-2054, 1979.
- Reliability Test System Task Force, “The IEEE Reliability Test System - 1996,” *IEEE Transactions on Power Systems*, vol. 14, pp. 1010-1020, 1999.

ABSTRACT

Optimal power flow (OPF) has been widely used in power system operation and planning. In deregulated environment of power sector, it is of increasing importance, for determination of electricity prices and also for congestion management. With a non-monotonic solution surface, classical methods are highly sensitive to starting points and frequently converge to local optimal solution or diverge altogether. The modified genetic algorithm is used for solving problem of optimal power flow. And for verification of proposed algorithm two standard test power system are used, IEEE 30 bus and IEEE 24 RTS.

OPTIMAL POWER FLOW USING MODIFIED GENETIC ALGORITHM

Darko Šošić
Jelena Stojković