

UNIVERZITET U PRIŠTINI SA PRIVREMENIM SEDIŠTEM
U KOSOVSKOJ MITROVICI

FAKULTET TEHNIČKIH NAUKA

Milena M. Jevtić

**ADAPTIVNA OPTIMIZACIJA
INSPIRISANA VETROM I ALGORITAM
ROJA NOĆNIH LEPTIRA U REŠAVANJU
PROBLEMA EKONOMIČNE
RASPODELE SNAGA GENERATORA**

Doktorska disertacija

Kosovska Mitrovica, 2018.

UNIVERSITY OF PRISTINA TEMPORARY SETTLED IN
KOSOVSKA MITROVICA
FACULTY OF TECHNICAL SCIENCES

Milena M. Jevtić

**ADAPTIVE WIND DRIVEN
OPTIMIZATION AND MOTH SWARM
ALGORITHM IN SOLVING ECONOMIC
EMISSION DISPATCH PROBLEM**

Doctoral Dissertation

Kosovska Mitrovica, 2018

<i>I Autor</i>	
Ime i prezime:	Milena M. Jevtić
Datum i mesto rođenja:	03.05.1986. Zaječar
Sadašnje zaposlenje:	Asistent na Tehničkom fakultetu u Boru Univerziteta u Beogradu

<i>II Doktorska disertacija</i>	
Naslov:	Adaptivna optimizacija inspirisana vetrom i algoritam noćnih leptira u rešavanju problema ekonomične raspodele snaga generatora
Broj stranica:	145
Broj slika:	34
Broj bibliografskih podataka:	87
Ustanova i mesto gde je rad izrađen:	Univerzitet u Prištini sa privremenim sedištem u Kosovskoj Mitrovici, Fakultet tehničkih nauka
Naučna oblast (UDK):	
Mentor:	Dr. Nenad Jovanović, vanredni profesor Univerziteta u Prištini sa privremenim sedištem u Kosovskoj Mitrovici

<i>III Ocena i odbrana:</i>	
Datum prijave teme:	22.05.2017. godine
Broj odluke i datum prihvatanja doktorske disertacije:	633/3-3 23.06.2017. godine
Komisija za ocenu podobnosti teme i kandidata:	1. Dr. Nenad Jovanović, vanr. prof. Univerziteta u Prištini sa privremenim sedištem u Kosovskoj Mitrovici, 2. Dr. Jordan Radosavljević, vanr. prof. Univerziteta u Prištini sa privremenim sedištem u Kosovskoj Mitrovici, 3. Dr. Darko Brodić, vanr. prof. Univerziteta u Beogradu
Komisija za ocenu i odbranu doktorske disertacije:	1. Dr. Dragiša Stanujkić, vanr. prof. Univerziteta u Beogradu, predsednik 2. Dr. Nenad Jovanović, vanr. prof. Univerziteta u Prištini sa privremenim sedištem u Kosovskoj Mitrovici, mentor 3. Dr. Jordan Radosavljević, vanr. prof. Univerziteta u Prištini sa privremenim sedištem u Kosovskoj Mitrovici, član
Datum odbrane disertacije:	

Apstrakt

U ovom radu su primenjeni algoritam roja noćnih leptira (MSA) i adaptivna optimizacija inspirisana vetrom (AWDO) za rešavanje nelinearnog problema ekonomične raspodele snaga (ERS) generatora u termoelektranama. Utvrđeno je da ovi algoritmi imaju visoku efikasnost u rešavanju ERS problema i izvršena je statistička analiza ponašanja ovih algoritama. Algoritmi MSA i AWDO su testirani na standardnim IEEE test sistemima sa 3 i 6 generatora i pokazali su bolje performanse u odnosu na algoritme primenjivane u publikovanoj literaturi. Zatim je problem ERS proširen problemom lanca snabdevanja električnom energijom na deregulisanom tržištu pa je takav integrisani problem rešavan primenom AWDO. Na rezultate dobijene testiranjem algoritama primenjeni su statistički parametarski i neparametarski testovi kako bi se utvrdila razlika u ponašanju algoritama pri dobijanju rezultata na pojedinačnim funkcijama ERS problema i na svim funkcijama zajedno i kako bi se utvrdilo da li se mogu generalizovati zaključci iz konkretnih skupova rešenja na celu populaciju mogućih rešenja. Rezultati statističke analize su pokazali da se algoritmi ponašaju različito za različite funkcije ERS problema tj., da jedan algoritam ne može biti najbolji za svaku funkciju. To znači da je pri rešavanju problema koji se sastoji od većeg broja funkcija bolje primeniti veći broj odgovarajućih algoritama umesto jednog.

Ključne reči: računarska inteligencija, evolucionarno računarstvo, optimizacija rojevima čestica, računari u obradi informacija, računarstvo u elektroenergetici.

Abstract

In this work, the metaheuristic optimization algorithms: Moth Swarm Algorithm (MSA) and Adaptive Wind Driven Optimization (AWDO) are applied to solve the nonlinear problem of the economic emission dispatch (EED) in thermal power plants. It was established that these algorithms have high efficiency in solving EED problem and a statistical analysis of the behavior of these algorithms was performed. The MSA and AWDO algorithms were tested on standard IEEE test systems with 3 and 6 generators and showed better performance compared to the algorithms applied in the published literature. Then the EED problem is expanded by the problem of the electricity supply chain on the deregulated market, and such integrated problem is solved using AWDO. On the results obtained by testing the algorithms, statistical parametric and nonparametric tests were applied in order to determine the difference in the behavior of the algorithms in obtaining the results on the individual functions of the EED problem and on all functions together, and in order to determine whether the conclusions from the concrete sets of solutions can be generalized on the whole population of possible solutions. The results of statistical analysis have shown that algorithms behave differently for different functions of the EED problem, i.e., that one algorithm can not be the best for each function. This means that when solving a problem consisting of a number of functions, it is better to apply a greater number of appropriate algorithms instead of one.

Key words: computational intelligence, evolutionary computation, particle swarm optimization, computers and information processing, power engineering computing.

ZAHVALNICA

Zahvaljujem se svima koji su mi pomagali tokom izrade disertacije a posebno: mentoru Prof. dr Nenadu Jovanoviću na izuzetno korisnoj stručnoj pomoći i stalnoj podršci koju mi je pružao tokom izrade disertacije, Prof. dr Jordanu Radosavljeviću na dragocenoj pomoći u oblasti primene metaheurističkih metoda u elektroenergetici i Prof. dr Dragiši Stanujkiću na pažljivom čitanju materijala disertacije i korisnim savetima. Takođe, najtoplije se zahvaljujem članovima svoje porodice koji su od početka doktorskih studija stalno pratili moj rad i pružali mi neprestanu podršku.

SADRŽAJ

1. UVOD.....	1
1.1 Predmet istraživanja	1
1.2 Polazne hipoteze	5
1.3 Ciljevi istraživanja.....	5
1.4 Metode istraživanja.....	6
1.5 Rezultati i doprinos.....	6
1.6 Struktura rada	8
2. PREGLED REZULTATA PRETHODNIH ISTRAŽIVANJA.....	10
2.1 Pregled MA za rešavanje problema ERS	10
2.2 Pregled rezultata statističke analize ponašanja MA	19
3. MSA.....	22
4. AWDO I WDO.....	29
4.1 CMAES	34
5. MODEL ERS.....	38
6. METODOLOGIJA REŠAVANJA ERS PROBLEMA PRIMENOM MSA I AWDO.....	41
6.1 Formiranje opšteg dijagrama toka	41
6.2 Formiranje koraka MSA i AWDO	41
6.3 Proširenje modela ERS.....	45
6.4 Objedinjeni model: ERS - lanac snabdevanja električnom energijom	45
7. REZULTATI TESTIRANJA MSA I AWDO	50
7.1 Rezultati testiranja MSA	50
7.1.1 Zaključak	53
7.2 Rezultati testiranja AWDO.....	57
7.2.1 Zaključak	62
8. REZULTATI REŠAVANJA PROBLEMA: ERS - LANAC SNABDEVANJA ..	64
8.1 Zaključak	65
9. REZULTATI STATISTIČKE ANALIZE PONAŠANJA MSA I AWDO.....	66
9.1 Primena statističkih testova za pojedinačne funkcije	67
9.2 Primena statističkih testova za grupu funkcija	76
9.3 Zaključak	79
10. ZAKLJUČAK.....	81

11. LITERATURA	85
12. PUBLIKOVANI RADOVI NA TEMU DOKTORSKE DISERTACIJE	94
PRILOG A. TABELE B-loss MATRICA I KOEFICIJENATA TROŠKOVA GORIVA I EMISIJE GASOVA	95
PRILOG B. TABELE REZULTATA TESTIRANJA ALGORITAMA I GRAFICI KONVERGENCIJE	97
B.1 Rezultati testiranja algoritama AWDO, MSA, PSOUSA i FA na IEEE test.....	97
sistemu sa 6 generatora (bez uticaja i sa uticajem ventila) i sa gubicima u	97
sistemu.	97
B.2 Rezultati testiranja algoritama AWDO, MSA, PSOUSA i FA na IEEE test....	107
sistemima sa 3 i sa 6 generatora, bez gubitaka u sistemu i bez uticaja ventila.....	107
PRILOG C. HISTOGRAMI I Q-Q GRAFICI ALGORITAMA AWDO, PSOUSA, MSA I FA.....	121
PRILOG D. SKRAĆENICE I OSNOVNE OZNAKE, PREMA REDOSLEDU POJAVLJIVANJA	131
PRILOG E. SPISAK TABELA.....	139
PRILOG F. SPISAK SLIKA	142
Prilog 1	i
Prilog 2	ii
Prilog 3	iii
Prilog 4	iv

1. UVOD

1.1 Predmet istraživanja

U poslednjih deset godina u naučnoj literaturi je predložen veliki broj optimizacionih metaheurističkih algoritama (MA) za rešavanje problema u nauci, tehnici, ekonomiji, industriji i operacionim istraživanjima. Primena egzaktnih gradijentnih metoda je otežana ili nemoguća pri optimizaciji nelinearnih neglatkih i nekonveksnih funkcija kojima se često opisuju ovi problemi pa se u tim slučajevima uspešno primenjuju stohastički MA. Problem kod neglatkih funkcija je taj što nije moguće naći izvod u svakoj tački dok nekonveksne funkcije imaju veći broj lokalnih minimuma koji se razlikuju od globalnog minimuma. Stohastička priroda MA se sastoji u tome što za dati skup slučajno odabranih početnih rešenja nekog problema algoritam daje procene konačnih rešenja tog problema.

Ciljevi optimizacije su različiti: minimizacija gubitaka i troškova energije, maksimizacija efikasnosti, profita, performansi i izlaznih veličina. U većini slučajeva krajnji cilj je dobijanje maksimalne proizvodnje ili profita na osnovu ograničenih resursa, količina novca i vremena. MA su nastali razvojem heurističkih algoritama. Pojam *heuristika* se može tumačiti kao “traženje“ ili “pronalaženje rešenja putem pokušaja i greške“ [1]. Heuristički algoritam je prilagođen strukturi i karakteristikama konkretnog problema. On daje kvalitetno rešenje problema u razumno vreme ali ne garantuje da je to optimalno rešenje. Drugim rečima, heuristički algoritam dolazi lako do približnog ali dovoljno dobrog rešenja. Izraz *meta* znači “nad” ili “višeg nivoa” pa se generalno može reći da su MA heuristički algoritmi “višeg nivoa” sa mogućnošću rešavanja složenih problema koje heuristički algoritmi ne mogu da reše [1]. MA daju opšta uputstva kako treba rešiti problem. Pri traženju rešenja, MA vrše slučajni izbor rešenja (randomizaciju) i lokalnu pretragu pa se MA mogu nazvati heurističkim algoritmima sa randomizacijom i lokalnom pretragom. Randomizacija je dobar način za prelazak sa lokalnog pretraživanja na globalno pretraživanje, što MA čini pogodnim za globalnu optimizaciju. MA vrši diverzifikaciju tj. generisanje većeg broja različitih rešenja da bi se istražio ceo prostor pretrage i intenzifikaciju, tj. fokusiranje na lokalni prostor pretrage kako bi se istražio taj deo prostora [1], [2], [3]. Istovremeno, tokom pretrage, MA vrši selekciju najboljih rešenja. Selekcijom najboljih rešenja, omogućava

se da rešenja postepeno konvergiraju ka optimalnom rešenju pri čemu diverzifikacija, koja se vrši randomizacijom, sprečava da rešenja budu zarobljena u lokalnim optimumima. Heuristički algoritmi zavise od vrste problema pa se dizajniraju i koriste za konkretan problem. Zbog efikasnijeg pretraživanja prostora, MA imaju opštiju primenu i mogu se prilagoditi za rešavanje bilo kojeg optimizacionog problema [2]. MA su najčešće dizajnirani tako da prate zakonitosti u prirodi pa se tada nazivaju prirodom inspirisani algoritmi. Prirodom inspirisani algoritmi su deo računarske inteligencije i dele se u dve glavne grupe: evolucione algoritme i algoritme rojeva (jata). Obe ove grupe MA se baziraju na populacijama tj. grupama jedinki pa se nazivaju populacioni MA. Svaka jedinka predstavlja jednog od kandidata rešenja u vidu realnog broja ili bita. Funkcija vrednosti rešenja (eng. *fitness function*) ocenjuje rešenje dodeljujući mu neku vrednost na osnovu koje se procenjuje koliko je rešenje blisko konačnom rešenju. Funkcija vrednosti rešenja najčešće je ekvivalentna samoj optimizacionoj funkciji cilja. Suština svih populacionih MA je iterativna korekcija rešenja, tj. generisanje nove populacije jedinki (novih rešenja) primenom stohastičkih algoritamskih operatora na jedinke iz tekuće populacije, što postepeno vodi populaciju ka rešenjima višeg kvaliteta [4]. Ključne performanse MA su brza pretraga velikog prostora mogućih rešenja i sposobnost pronalaženja globalnog optimalnog rešenja uz istovremeno izbegavanje lokalnih optimuma. Način na koji se definišu algoritamski operatori predstavlja suštinu konkretnog MA. Efikasnost i performanse MA zavise i od pravilnog podešavanja odgovarajućih algoritamskih parametara. Opšta struktura populacionih MA najčešće se predstavlja sledećim koracima:

Korak 0:	Izabрати број јединки $m \geq 2$ у простору кандидата решења, параметре
Priprema	алгоритма, максималан број итерација t_{max} и <i>fitness</i> функцију $f(x)$. Пodesити бројач итерација на $t = 0$.

Korak 1:	Izabрати случајну почетну популацију јединки (кандидата решења):
Inicijalizacija	$x_i^{(0)} \in R^n, i = 1, 2, \dots, m$. Izračunati $f^* = \min \left\{ f \left(x_i^{(0)} \right), i = 1, \dots, m \right\}, \quad x^* = \arg f^*.$

Korak 2: Generisati novu populaciju jedinki, $x_i^{(t+1)}$, primenom algoritamskih operatora na svaku jedinku iz tekuće populacije.

Ažuriranje $x_i^{(t)}$

Izračunati $f_{\min} = \min \{ f(x_i^{(t+1)}), i = 1, \dots, m \}$.

Ako je $f_{\min} < f^*$, staviti $f^* = f_{\min}$ i $x^* = \arg f_{\min}$.

Korak 3: Ako je $t = t_{\max}$, zaustaviti algoritam. U suprotnom zadati $t = t + 1$ i vratiti se na korak 2.

Kraj

Usvojiti rešenje x^* kao konačno približno rešenje problema.

Jedan od problema za čije rešavanje je u novije vreme u literaturi predložen veliki broj prirodno inspirisanih populacionih MA je ekonomična raspodela snaga (ERS) generatora u termoelektranama (eng. *economic emission dispatch*). ERS je ključni problem u planiranju i radu elektroenergetskog sistema u kojem se minimizira funkcija troškova goriva ili funkcija količine emitovanih toksičnih gasova ili istovremeno funkcija troškova goriva i funkcija količine emitovanih toksičnih gasova (SO_x , CO_2 i NO_x). Minimizacija ovih funkcija se vrši podešavanjem izlaznih snaga generatora za zadato opterećenje sistema i zadata ograničenja u sistemu. Funkcije cilja su složene i sastoje se od kombinacija kvadratne, sinusoidalne i eksponencijalne funkcije. U ovom radu su primenjeni algoritam roja noćnih leptira (MSA) (eng. *Moth Swarm Algorithm*) [5] i adaptivna optimizacija inspirisana vetrom (AWDO) (eng. *Adaptive Wind Driven Optimization*) [6] za rešavanje nelinearnog problema ERS. Algoritmi MSA i AWDO su odabrani zbog poboljšanih performansi u odnosu na druge populacione MA. MSA ima dva optimizaciona operatora: vektor *Levy*-mutacije za poboljšanje procesa diverzifikacije i mehanizma asocijativnog učenja (ALIM) (eng. *Associative Learning Mechanism*) za poboljšanje pretraživanja u uskim domenima. AWDO je hibridni algoritam koji se sastoji od dva algoritma: optimizacije inspirisane vetrom (WDO) (eng. *Wind Driven Optimization*) [7] i evolucione strategije adaptacijom matrice kovarijansi (CMAES) (eng. *Covariance Matrix Adaptation Evolution Strategy*) [8], [9]. Dobre performanse AWDO su omogućene time što WDO vrši uspešno pretraživanje rešenja a brzi algoritam CMAES vrši optimizaciju parametara algoritma u

svakoj iteraciji. Predloženi MA za rešavanje ERS problema su testirani i upoređivani sa drugim algoritmima, pri čemu su korišćeni standardni elektroenergetski test sistemi sa različitim brojevima generatora.

U većini publikovanih radova, predloženi algoritmi za rešavanje ERS problema se upoređuju sa drugim algoritmima na osnovu najboljeg rešenja, srednje vrednosti, vrednosti standardne devijacije i dijagrama konvergencije rešenja dobijenih za konkretan problem. U publikovanim radovima nisu primenjivani parametarski i neparametarski statistički testovi za analizu rezultata i ponašanja algoritama u okviru cele populacije mogućih rešenja. Međutim, u nekim radovima [10], [11], [12], pri rešavanju drugih problema iz oblasti računarske inteligencije, predlažu se metode za primenu parametarskih i neparametarskih testova za upoređivanje i analizu performansi MA na pojedinačnim skupovima podataka i na višestrukim skupovima podataka. Na bazi ovih metoda istraživači su izvodili zaključke o tome da li postoje statističke razlike između algoritama i da li su te razlike realne ili slučajne. U ovom radu je predložena i po prvi put primenjena procedura primene parametarskih i neparametarskih statističkih testova u analizi rezultata dobijenih na ERS problemu primenom MA. Za ovu analizu su odabrana 4 MA koji su dali najbolje rezultate u rešavanju ERS problema određenih karakteristika i dimenzija. Na bazi ovih rešenja izvršeno je upoređenje odabranih MA na skupovima rešenja pojedinačnih funkcija ERS i na skupu rešenja svih funkcija zajedno.

Poslednjih nekoliko godina mnogi istraživači dodatno proširuju model ERS uzimajući u obzir dodatne uticaje kao što su: vetroelektrane i solarne elektrane u sistemu sa uzimanjem u obzir uticaja na životnu sredinu i bez tog uticaja; sistemi za čuvanje energije; promene i uticaj potrošnje i upravljanje potrošnjom. Na taj način, ERS problem postaje još složeniji a dizajniranje i izbor algoritama za njegovo rešavanje postaju još važniji. U nekim radovima ERS problem se uključuje u modele lanaca snabdevanja deregulisanog tržišta električne energije. Tako je u [13] razvijen optimizacioni model zasnovan na dvostrukoj Benderovoj dekompoziciji i na ERS u sistemu sa kombinovanom proizvodnjom toplote i električne energije, u cilju postizanja maksimalnog profita i minimalne emisije štetnih gasova. U [14] je predložen model efikasnog liberalizovanog tržišta električne energije, koji obuhvata uticaj virtuelnih elektrana i ERS. U [15] je razvijen model koji povezuje optimalno donošenje odluka

kod proizvođača goriva, proizvođača električne energije, kupaca i nezavisnih operatera sistema primenom ugovora o smanjenju cena goriva sa povećanjem količina isporučenog goriva. U [16] je razvijen model lanca snabdevanja električnom energijom koji je integrisan sa mrežom tržišta gorivom. U ovom radu je razvijen model koji povezuje ERS i lanac snabdevanja deregulisanog tržišta električne energije. Na ovom modelu je, zatim, primenjen algoritam AWDO koji je prethodno testiran na standardnom IEEE test sistemu sa 6 generatorskih jedinica.

1.2 Polazne hipoteze

Postavljene su tri polazne hipoteze. Prva hipoteza je da metaheuristički algoritmi MSA i AWDO, kao novi algoritmi unapređeni dodatnim optimizacionim operatorima i hibridizacijom, mogu dati bolja rešenja složenog nelinearnog problema ERS u odnosu na druge MA koji su predloženi u literaturi. Druga hipoteza je da se problem ERS može dodatno proširiti problemom lanca snabdevanja na deregulisanom tržištu električne energije i kao takav rešavati primenom MA. Treća polazna hipoteza je da jedan MA ne može biti najbolji za svaku funkciju višeciljnog problema kakav je ERS problem već da treba primeniti veći broj algoritama odabranih na osnovu statističke analize ponašanja algoritama primenom parametarskih i neparametarskih testova.

1.3 Ciljevi istraživanja

Ciljevi istraživanja sprovedenih u ovoj disertaciji su: (i) da se po prvi put izvrši testiranje novih unapređenih hibridnih algoritama MSA i AWDO za rešavanje složenog ERS problema i da se pokaže da oni daju kvalitetna rešenja koja su bolja u odnosu na rešenja dobijena primenom drugih ranije predloženih MA (ii) da se razvije novi objedinjeni model ERS i lanca snabdevanja na deregulisanom tržištu električne energije i da se, zatim, na ovom kompleksnom modelu implementiraju predloženi MA i (iii) da se razvije i primeni postupak procene statističkog ponašanja većeg broja MA u rešavanju kompleksnih problema sa većim brojem funkcija cilja, pri čemu bi se vršila statistička analiza primenom parametarskih i neparametarskih testova na rezultatima dobijenim za pojedinačne funkcije i za sve funkcije istovremeno.

1.4 Metode istraživanja

Da bi se izvršilo testiranje predloženih algoritama MSA i AWDO najpre je formiran opšti dijagram toka za rešavanje ERS problema pomoću bilo kog populacionog MA. Zatim su formirani koraci za rešavanje ERS problema pomoću algoritama MSA i AWDO i urađeni su odgovarajući programi za računar u MATLAB-u. Testiranje algoritama je vršeno posle velikog broja puštanja algoritma u rad. Primenjene su statističke metode za dobijanje statističkih pokazatelja algoritama i MATLAB softver za dobijanje krivih konvergencije.

Modifikacija ERS modela za potrebe njegove integracije sa modelom lanca snabdevanja na deregulisanom tržištu električne energije izvršena je na osnovu Kronove formule gubitaka snage u elektroenergetskom sistemu. Lanac snabdevanja na deregulisanom tržištu električne energije modeliran je na osnovu uslova ravnotežnog stanja u lancu snabdevanja i primenom teorije igara tj., izvođenjem *Nash*-ove ravnoteže.

Statistička analiza rezultata dobijenih pomoću MA vršena je primenom parametarskih testova: *Kolmogorov-Smirnov*, *Shapiro-Wilk*, *D'Agostino-Pearson*, Levenovog test, uparenog *t*-testa i neparametarskih testova: *Wilcoxon* testa i *Friedman* testa. Rezultati ovih testova, uključujući histograme ferekvencija dobijenih rezultata i Q-Q grafike, dobijani su pomoću softvera za statističku analizu rezultata SPSS (eng. *Statistical Package for the Social Sciences*).

1.5 Rezultati i doprinos

U ovom radu, predloženi algoritmi MSA i AWDO su testirani i upoređivani sa drugim algoritmima, pri čemu su korišćeni standardni elektroenergetski test sistemi sa različitim brojevima generatora. Komparativna analiza rezultata je pokazala da je standardna devijacija rezultata manja u slučaju primene MSA i AWDO u odnosu na druge testirane algoritme. Minimalne vrednosti troškova goriva i emisije NO_x i SO_x gasova, dobijene primenom MSA i AWDO su manje nego odgovarajuće vrednosti dobijene u publikovanoj literaturi primenom drugih MA na istim test sistemima. Profili konvergencije su pokazali da MSA i AWDO imaju najbolje konvergentne osobine u

odnosu na druge MA. Rezultati simulacije su pokazali da AWDO daje bolje rezultate od MSA u slučaju primene složenijih funkcija cilja, tj., pri uzimanju u obzir uticaja efekta otvaranja ventila u termoelektranama. Zbog toga, AWDO daje i najbolje ekonomske efekte. Na osnovu svih rezultata dobijenih u ovom testu, algoritam AWDO je pokazao da ima najbolje osobine robusnosti, efektivnosti i efikasnosti u odnosu na druge algoritme što ga čini boljim algoritmom od svih do sada predloženih MA za rešavanje ERS problema sa složenim funkcijama koje sadrže nelinearnosti izazvane efektom ventila u termoelektranama. Nakon testiranja algoritama, AWDO je uspešno primenjen na objedinjenom modelu ERS i lanca snabdevanja električnom energijom, koji je izveden u ovom radu. Izvršen je proračun tokova snaga na tržištu električne energije i proračun cena električne energije minimizacijom troškova goriva i emisije štetnih gasova i maksimizacijom profita učesnika u lancu snabdevanja.

Rezultati statističke analize primenom parametarskih i neparametarskih testova su pokazali da se algoritmi ponašaju različito za različite funkcije ERS problema tj., da jedan algoritam ne može biti najbolji za svaku funkciju problema. To je u skladu sa teoremom "Nema besplatnog ručka" (eng. "*No free lunch*") [17] koja se odnosi na optimizacione algoritme i iz koje proističe zaključak da: (i) nije moguće pronaći jedan optimizacioni algoritam koji će biti najbolji za sve probleme i (ii) da bi se dizajnirao algoritam sa odgovarajućim karakteristikama, potrebno je poznavati problem koji se pomoću njega rešava.

Iz dobijenih rezultata sledi da su glavni doprinosi disertacije sledeći: (i) Predloženi algoritmi MSA i AWDO za rešavanje kompleksnog ERS problema daju kvalitetna rešenja koja su bolja u odnosu na rešenja dobijena primenom drugih ranije predloženih MA. To znači da se oni mogu uspešno uključiti u softvere pomoću kojih se vrši upravljanje potrošnjom goriva i količinom emisije gasova u termoelektranama na bazi ulazno-izlaznih karakteristika generatora; (ii) Predloženi MA se mogu primeniti na proširenom modelu ERS, koji je razvijen u ovom radu, radi dobijanja optimalnih tokova snaga i maksimalnog profita u lancu snabdevanja električnom energijom minimizacijom troškova goriva i/ili emisije štetnih gasova. Ova procedura se može primeniti pri upravljanju tržištem električne energije i pri višekriterijumskom donošenju odluka od strane učesnika u lancu snabdevanja; (iii) Predloženi postupak analize statističkog ponašanja većeg broja MA u rešavanju kompleksnih problema sa većim brojem funkcija

cilja omogućuje bolji izbor MA, pri kojem se problem efikasnije rešava primenom većeg broja MA umesto jednog.

Valorizacija rezultata i doprinosa disertacije izvršena je publikovanjem radova u časopisima sa SCI liste, koji su navedeni u Spisku publikovanih radova na temu doktorske disertacije.

1.6 Struktura rada

Ovaj rad se sastoji od 12 glava sa odgovarajućim poglavljima. U drugoj glavi disertacije dat je pregled literature koja se bavi dosadašnjom primenom različitih MA za rešavanje ERS problema. U ovoj glavi se daje i pregled rezultata statističke analize ponašanja MA, pri rešavanju različitih problema računarske inteligencije, primenom parametarskih i neparametarskih testova i *benchmark* funkcija kao funkcija cilja.

U trećoj i četvrtoj glavi detaljno su opisani algoritmi MSA i AWDO koji se po prvi put primenjuju za rešavanje ERS problema. MSA je odabran jer ima bolje performanse u odnosu na klasične algoritme rojeva zahvaljujući uvođenju dva nova optimizaciona operatora: Vektora *Levy*-mutacije za poboljšanje procesa diverzifikacije i ALIM za poboljšanje pretraživanja u uskim domenima. AWDO predstavlja hibridni MA sačinjen od algoritama WDO i CMAES. Dobre performanse AWDO su omogućene time što WDO vrši uspešno pretraživanje rešenja a brzi algoritam CMAES vrši optimizaciju parametara algoritma u svakoj iteraciji.

U petoj glavi se daje opis matematičkog modela ERS sa svim mogućim funkcijama cilja: funkcijom troškova goriva generatorskih jedinica, funkcijom emisije štetnih gasova i kombinovanom funkcijom troškova goriva i emisije gasova, koje menjaju svoje oblike zavisno od toga da li se uzimaju u obzir gubici u mreži i efekat sekvencijalnog otvaranja ventila u termoelektranama.

U šestoj glavi se opisuje metodologija za primenu MSA i AWDO u rešavanju ERS problema, pri čemu se formiraju opšti dijagram toka MA za rešavanje ERS problema i koraci pri primeni MSA i AWDO. U ovoj glavi se za primenu MSA i AWDO razvijaju dva nova modela proširenja ERS problema: (i) model ekonomske raspodele količina snaga generatora, koje se prodaju na tržištu električne energije i (ii) integrisani model ERS i lanca snabdevanja električnom energijom. U prvom od ova dva

predložena modela se vrši proširenje ERS problema tako što se pri minimizaciji funkcija cilja, pored optimalnih izlaznih snaga generatora, određuju i udeli snaga generatora u gubicima sistema i snage koje se sa pojedinačnih generatora isporučuju tržištu. Drugi model, koji se predlaže u ovoj glavi, obuhvata matematički model lanca snabdevanja na spot (balansnom) tržištu električne energije, koji je povezan sa ERS modelom. Objedinjeni model je namenjen za proračun tokova snaga na spot tržištu i cena, uzimajući u obzir ERS i maksimalni profit proizvođača i snabdevača električnom energijom. Za izvođenje objedinjenog modela izvedena je i *Nash*-ova ravnoteža u lancu snabdevanja električnom energijom [18].

Sedma glava obuhvata testiranje predloženih algoritama MSA i AWDO na standardnim elektroenergetskim IEEE test sistemima sa 3 i 6 generatora. Predloženi MSA i AWDO se upoređuju sa drugim MA koji su predloženi u literaturi za rešavanje ovog problema i daju se njihove prednosti.

U osmoj glavi se, primenom algoritma AWDO rešava primer sa objedinjenim modelom ERS i lanca snabdevanja pri čemu se određuju tokovi snaga u lancu snabdevanja, cene električne energije i maksimalni profiti proizvođača i snabdevača električnom energijom za minimalne troškove i/ili minimalnu emisiju gasova.

U devetoj glavi se vrši statistička analiza rezultata dobijenih primenom većeg broja MA pri rešavanju problema ERS. Primenuju se parametarski i neparametarski testovi na rezultatima dobijenim na pojedinačnim funkcijama ERS ili na svim funkcijama koje opisuju problem, istovremeno. Utvrđuje se da li su rezultati realni ili slučajni tj., da li se mogu generalizovati zaključci iz konkretnih skupova rešenja na celu populaciju mogućih rešenja. Utvrđuje se koji MA daju rezultate koji se podvrgavaju parametarskim funkcijama raspodele a koji MA daju rezultate koji se ne podvrgavaju funkcijama raspodele. Na bazi sprovedene statističke analize utvrđuje se da li jedan MA može biti najbolji za sve funkcije ERS ili je prihvatljivije primeniti veći broj MA odabranih među onim koji su se pokazali kao najbolji na jednoj ili više pojedinačnih funkcija.

Deseta glava sadrži zaključke i glavne doprinose disertacije. Jedanaesta glava sadrži spisak korišćene literature a u dvanaestoj glavi je dat spisak publikovanih radova na temu disertacije. U prilogu A su date korišćene tabele preuzete iz literature a prilozima B i C sadrže dopunske rezultate istraživanja. U prilogima D, E i F dati su spiskovi korišćenih skraćenica, tabela i slika.

2. PREGLED REZULTATA PRETHODNIH ISTRAŽIVANJA

2.1 Pregled MA za rešavanje problema ERS

U ovom poglavlju se daje detaljni pregled populacionih MA koji su predloženi u literaturi za rešavanje problema ERS. U pregledu se opisuju zakonitosti u prirodi koje se koriste za definisanje algoritamskih operatora MA, varijante problema ERS na kojima su konkretni MA primenjeni, rezultati, prednosti i nedostaci pojedinačnih MA. U [19] se koristi algoritam diferencijalne evolucije (DE) (eng. *Differential Evolution*) [20] za rešavanje ERS problema pri čemu se uvodi dodatni postupak kojim se isključuju iz rada generatori sa malom efikasnošću tj. generatori sa povećanim troškovima goriva i povećanim gubicima u mreži. Na taj način se smanjuju ukupni troškovi goriva u elektrani. DE generiše rešenje optimizacionog problema iz skupa mogućih rešenja tako što koristi tehnike inspirisane prirodnom evolucijom, ukrštanje i mutaciju, i primenjuje vektore razlika. Njegove prednosti su: dobre mogućnosti lokalnog pretraživanja, brza konvergencija, jednostavno korišćenje procesa i jednostavna struktura. DE je primenjen i u [21] gde je problem ERS rešavan tako što su zadavane granice emisije gasova u skladu sa zahtevima za zaštitu životne sredine. U [22] DE je kombinovan sa metodom ansambla selekcije kako bi se učinio efikasnijim i primenjen je na dinamičkom modelu ERS u kojem se potrošnja energije menja u funkciji od vremena i u kojem se uzima u obzir prisustvo vetroelektrana u sistemu. Za rešavanje ERS problema u [23] je predložena hibridna varijanta DE u kojoj se DE kombinuje sa algoritmom inspirisanim biogeografijom (BBO) (eng. *Biogeography-based Optimization*). Biogeografija proučava raspodelu različitih bioloških vrsta. BBO pretražuje prostor mogućih rešenja kroz dva glavna koraka: migraciju i mutaciju. Kombinacija DE i BBO omogućuje bržu konvergenciju i kvalitetnije rešenje ERS problema. BBO je primenjen za rešavanje ERS problema i u [24], [25]. U [24] problem ERS je rešavan uzimanjem u obzir nelinearnosti zbog efekta otvaranja ventila u termoelektrani i ograničenja snage i brzine promene snage generatora. DE modifikovan plemenima (podskupovima u populaciji rešenja, u kojima individue komuniciraju među sobom) (Tribe-MDE) (eng. *Tribe-Modified Differential Evolution Algorithm*) [26] je primenjen za rešavanje ERS u cilju generisanja većeg broja različitih rešenja u odnosu na DE i, time, sprečavanja prerane

konvergencije. Pored DE za rešavanje problema ERS primenjeni su i drugi evolucionari algoritmi. Jedan od njih je genetski algoritam (GA) (eng. *Genetic Algorithm*) [27] koji generiše rešenja za optimizaciju problema korišćenjem tehnika inspirisanih prirodnom evolucijom kao što su: nasleđivanje, genetska mutacija, selekcija i genetsko ukrštanje. Kod njega se pri traženju rešenja primenjuje i tzv. elitistička selekcija kojom se obezbeđuje da se najbolje rešenje u populaciji ne pogoršava u narednim generacijama. Teorija GA je dugi niz godina razvijana i dopunjavana u cilju poboljšanja performansi pri rešavanju onih problema koji su bili teški za GA. U [28], [29] primenjuju se GA i neke od poboljšanih varijanti GA, kao što su: genetski algoritam sortiranja nedominiranih rešenja (NSGA) (eng. *Non-dominated Sorting Genetic Algorithm*) [30]; Unapređena verzija NSGA - elitistički genetski algoritam sortiranja nedominiranih rešenja (NSGA II) (eng. *Elitist Multiobjective Genetic Algorithm*) [31] i Pareto genetski algoritam sa nišama (NPGA) (eng. *Niched Pareto Genetic Algorithm*) [32]. NSGA je prošireni GA namenjen za rešavanje višeciljnih optimizacionih problema. Pomoću NSGA se bira jedno rešenje iz skupa nedominiranih rešenja (Pareto rešenja), koje je najefikasnije za više funkcija istovremeno. Algoritmi NSGA i NSGA II razlikuju se od GA u načinu rada operatora selekcije, dok su operatori ukrštanja i mutacije ostali isti. U njima se pre operacije selekcije vrši tzv. sortiranje populacije na bazi individualne nedominirnosti. NPGA vrši podelu populacije na veći broj stabilnih grupa (niša) unutar kojih se nalazi optimalno rešenje. Na taj način se u prostoru pretraživanja dobija veći broj lokalnih optimuma (rešenja), koji se zadržava tokom celog procesa evolucije kako bi se izbeglo zaustavljanje algoritma u nekom od lokalnih minimuma.

Za rešavanje problema ERS korišćeni su MA razvijeni na bazi inteligencije rojeva, jata i grupa živih bića. Neki od ovih MA su: optimizacija rojevima čestica (PSO) (eng. *Particle Swarm Optimization*) [33]; algoritam veštačke kolonije pčela (ABC) (eng. *Artificial Bee Colony*) [34]; algoritam svica (FA) (eng. *Firefly Algorithm*) [35]; algoritam bakterijskog traganja za hranom (BFA) (eng. *Bacterial Foraging Algorithm*) [36]; algoritam simbiotskih organizama (SOS) (eng. *Symbiotic Organisms Search*) [37]; algoritam planktonskih krilova (KHA) (eng. *Krill Herd Algorithm*) [38]; optimizator sivih vukova (GWO) (eng. *Grey Wolf Optimizer*) [39].

U [40] je primenjen PSO za rešavanje ERS problema u sistemu koji pored termoelektrana obuhvata i veći broj solarnih elektrana. Time je problem ERS proširen

na distribuiran sistem sa obnovljivim izvorima električne energije što je u skladu sa sve većim interesom za primenu obnovljivih izvora električne energije. PSO simulira kretanje jata ptica ili roja čestica primenom nekoliko osnovnih pravila. Potencijalna rešenja su položaji čestica (ptica) koje se kreću u prostoru pretraživanja. Čestice se opisuju svojim položajem u roju i u odnosu na susedne čestice, brzinom kretanja i informacijom o svom do tada najboljem položaju. Promenom položaja čestica tokom iterativnog procesa modelira se proces traženja najboljeg rešenja. Jedna od poboljšanih varijanti PSO je paralelna optimizacija rojevima čestica (PSPSO) (eng. *Parallel Particle Swarm Optimization*) [41]. Primenom ovog MA za rešavanje složenog ERS problema smanjuje se vreme izračunavanja tako što se vrše paralelna izračunavanja i ažuriranja pozicije i brzine na kraju svake iteracije. Druga proširena varijanta PSO koja je predložena za višeciljno rešavanje ERS problema je višeciljna optimizacija rojevima čestica (MOPSO) (eng. *Multiobjective Particle Swarm Optimization*) [42]. MOPSO redefiniše “*global best*” i “*local best*” jedinke za potrebe višeciljne optimizacije. Uvedeni su algoritam klasterovanja kojim se određuje dimenzija skupa Pareto-optimalnih rešenja i *fuzzy* mehanizam za dobijanje najboljeg kompromisnog rešenja. U [43] se za rešavanje ERS problema predlaže algoritam modifikovane adaptivne θ -optimizacije rojevima čestica (MA θ -PSO) (eng. *Modified Adaptive θ -Particle Swarm Optimization*). To je unapređena varijanta θ -PSO algoritma. θ -PSO se bazira na primeni vektora faznog ugla i generiše kvalitetno rešenje za kraće vreme nego PSO i druge evolucione metode. Uvođenjem nove mutacije, MA θ -PSO sprečava stagnaciju koja može da se javi pri primeni algoritma θ -PSO, kada vrednost čestice ne može da se popravi ni posle nekoliko generacija. Takođe, MA θ -PSO primenjuje *fuzzy If/Than* pravilo da bi podesio parametre θ -PSO i tehniku *fuzzy* klasterovanja da bi kontrolisao i održavao dimenziju grupe nedominiranih rešenja. Jedna od hibridnih varijanti MA koja se predlaže za uspešno rešavanje ERS problema sa konfliktnim ciljnim funkcijama i velikim brojem ograničenja je višeciljni optimizacioni algoritam zasnovan na PSO i DE [44]. U ovom algoritmu PSO ima vremenski promenljive koeficijente ubrzanja i dizajniran je da istraži ceo pretraživački prostor dok se DE koristi za eksploataciju podprostora sa rasejanim rešenjima.

ABC je MA koji se koristi za rešavanje različitih problema. On se zasniva na inteligenciji rojeva pčela. U ABC roj pčela se sastoji iz tri vrste veštačkih pčela

(agenata): radilica, posmatrača i izviđača. Izviđači vrše slučajnu pretragu izvora hrane (rešenja), radilica sakuplja nektar (hranu) sa cveta a posmatrači čekaju u košnici. Količina nektara predstavlja kvalitet rešenja (*fitness* vrednost). Broj pčela radilica jednak je broju potencijalnih rešenja (cvetova). Polovina roja pčela su radilice a polovina posmatrači. Neke od radilica, kada preuzmu celokupnu hranu sa cveta, postaju izviđači. U ovom MA proces intenzifikacije vrše radilice i posmatrači a diverzifikaciju izviđači. Za rešavanje ERS problema primenjene su neke od unapređenih varijanti ABC. U [45] primenjeni su algoritmi: inkrementalna veštačka kolonija pčela (IABC) (eng. *Incremental Artificial Bee Colony*) i inkrementalna veštačka kolonija pčela sa lokalnim pretraživanjem (IABC-LS) (eng. *Incremental Artificial Bee Colony with Local Search*). U IABC se tokom vremena povećava broj izvora hrane i broj radilica i posmatrača. Posle svake iteracije populacija raste sve dok roj ne dostigne maksimalnu veličinu populacije. Ovaj proces omogućuje veću intenzifikaciju i bržu konvergenciju rešenja. Zbog povećane intenzifikacije, u IABC postoji mogućnost stagnacije zbog upadanja u lokalne minimume. U IABC-LS uvodi se dodatni mehanizam lokalnog pretraživanja koji se sprovodi u svakoj iteraciji i kojim se otklanja navedeni mogući nedostatak IABC. Algoritmi IABC i IABC-LS su pokazali dobre rezultate u rešavanju ERS problema sa ograničenjima i zabranjenim zonama rada generatora. Veštačka kolonija pčela sa dinamičkom veličinom populacije (ABCDP) (eng. *Artificial Bee Colony Algorithm with Dynamic Population Size*) je MA koji je predložen u [46] za rešavanje ERS problema velikih dimenzija. On ima poboljšane efikasnost i robustnost u odnosu na IABC-LS što je posledica smanjenja broja podešavajućih parametara. U [47] za rešavanje ERS problema primenjena je varijanta ABC sa verovatnoćom pri izboru rešenja (PS-ABC) (eng. *Probability-Selection Artificial Bee Colony Algorithm*) i predložena poboljšana varijanta EPS-ABC (eng. *Enhanced Probability-Selection Artificial Bee Colony Algorithm*). U obe varijante radilice istražuju okolinu dodeljenog izvora hrane korišćenjem tri jednačine mutacije, na osnovu kojih se bira optimalno rešenje. Te jednačine su različite za ove dve varijante. Takođe i šeme pretrage pčele-izviđača se razlikuju. U slučaju primene EPS-ABC za rešavanje problema ERS konvergencija je brža a sprečena je mogućnost prerane konvergencije. Rezultati su dobijeni na test primerima ERS problema sa uzimanjem u obzir gubitaka u sistemu, različitih vrsta goriva, efekta ventila i ograničenja količine toksičnih gasova. Dobijeni

rezultati su bolji u odnosu na PS-ABC i neke druge MA koji su primenjeni u radu. Optimizacija inspirisana parenjem pčela (HBMO) (eng. *Honey Bee Mating Optimization*) je još jedan MA u kome se pretraživanje rešenja bazira na inteligenciji roja pčela. U [48] je HBMO primenjen za rešavanje ERS problema pri čemu se predlaže i njegova unapređena varijanta interaktivna optimizacija inspirisana parenjem pčela (IHBMO) (eng. *Interactive Honey Bee Mating Optimization*). U IHBMO se, pored realnog procesa parenja pčela, koristi i Njutnov zakon gravitacije koji deluje između pčele matice i odabranih pčela trutova. Uvođenjem Njutnovog zakona gravitacije u HBMO postignute su bolje lokalne i globalne pretraživačke sposobnosti novog IHBMO. Takođe, pri rešavanju ERS problema kao višeciljnog problema dobijaju se dobro raspoređena Pareto rešenja a korišćenjem teorije *fuzzy* skupova kvalitetno kompromisno rešenje. Njutnov zakon gravitacije, tj. univerzalni zakon gravitacije koji opisuje gravitacionu silu privlačenja dva tela primenjen je i u drugim MA. Jedan od njih je gravitacioni pretraživački algoritam (GSA) (eng. *Gravitational Search Algorithm*) [49]. U GSA, pretraživački agenti predstavljaju objekte čije se performanse izražavaju njihovim masama. Između objekata deluju privlačne gravitacione sile usled kojih se objekti globalno kreću ka objektima većih masa. Posle određenog vremena svi objekti biće privučeni od strane objekta koji ima najveću masu. Ova masa predstavlja optimalno rešenje. Tokom procesa pretraživanja rešenja izračunavaju se mase (na osnovu *fitness* vrednosti) i njihova ubrzanja, brzine i pozicije tokom kretanja. U [50] GSA je primenjen za rešavanje višeciljnog ERS problema koji se primenom težinskih faktora pretvara u problem sa jednom funkcijom cilja. U [51] se primenom GSA problem ERS rešava dinamički, tj. ERS generatora se određuje u vremenu i s obzirom na ograničenja i prekide rada generatora. U cilju ubrzanja konvergencije u [52] se umesto GSA predlaže modifikovana varijanta GSA, tj. gravitacioni pretraživački algoritam primenom suprotnih brojeva (OGSA) (eng. *Opposition-Based Gravitational Search Algorithm*). U njemu se u fazi inicijalizacije ocenjuju *fitness* vrednosti rešenja koja su slučajno odabrana i rešenja koja su njima suprotna (u odnosu na sredinu intervala). U nastavku procesa pretraživanja, uzimaju se ona rešenja koja su bliža krajnjem rešenju (što je procenjeno na bazi *fitness* vrednosti). Na taj način se ubrzava konvergencija. Isti postupak se primenjuje i tokom daljeg odvijanja procesa generisanja rešenja. Za efikasnije rešavanje ERS problema u nekim radovima je vršena hibridizacija

GSA sa drugim algoritmima. Tako je u [53] primenjen hibridni PSOGSA algoritam [54] dobijen hibridizacijom GSA sa PSO. On ima bolje mogućnosti izbegavanja lokalnih minimuma i bržu konvergenciju u odnosu na standardne PSO i GSA. U njemu su integrisani sposobnost društvenog razmišljanja izražena preko *gbest* vrednosti u PSO i lokalne mogućnosti pretraživanja GSA. To je postignuto drugačijim jednačinama ažuriranja brzine i pozicije agentata. Slična ideja je realizovana u hibridnom algoritmu HPSO-GSA koji je za rešavanje ERS problema predložen u [55]. U njemu se ažuriraju pozicije agenata, zajedno sa brzinom u PSO i ubrzanjem u GSA. Efikasnost rezultata je potvrđena na rešavanju različitih varijanti ERS problema sa ograničenjima i zabranjenim zonama rada generatora, sa različitim vrstama goriva i sa složenim karakteristikama zbog efekta ventila i gubitaka u sistemu. Jedan od MA iz grupe algoritama inspirisanih rojevima je algoritam bakterijske potrage za hranom (BFA) (eng. *Bacterial Foraging Algorithm*). BFA je inspirisan ponašanjem bakterije *Escherichia coli* pri njenom traganju za hranom. *Escherichia coli* bakterije su prisutne u ljudskim crevima i imaju strategiju potrage za hranom, kojom upravljaju četiri procesa: hemotaksa, reprodukcija, eliminacija i disperzija. Bakterije se grupišu u rojeve u kojima dobijaju socijalno ponašanje i sistem regulacije u potrazi za hranom. BFA koristi zakonitost prirodne selekcije globalne optimalne bakterije koja ima najbolju strategiju hranjenja. Hemotaksa je proces koji simulira kretanje bakterija plivanjem i tumbanjem pomoću flagela. Bakterije se organizuju i grupišu pomoću signala privlačenja/odbijanja. U procesu reprodukcije najmanje zdrave bakterije se zamenjuju zdravim. Nagle promene sredine u kojoj se bakterije kreću mogu da izazovu teške probleme koji se simuliraju procesom eliminacije i disperzije. Jedini cilj bakterije je da obezbedi dovoljnu količinu hranljive supstance izbegavajući štetne supstrate. U [56] je predložena modifikovana varijanta BFA za rešavanje ERS problema: modifikovani algoritam bakterijske potrage za hranom (MBFA) (eng. *Modified Bacterial Foraging Algorithm*). MBFA vrši modifikaciju izraza u kojima se opisuje hemotaksična faza, u cilju ubrzanja konvergencije. Pomoću BFA može da se rešava problem kao višeciljni, npr., bakterija može da teži i dovoljnoj količini hrane i optimalnoj temperaturi. Autori [57] predlažu drugu modifikovanu varijantu BFA koja je pogodna za rešavanje ERS problema kao višeciljnog problema. Ovaj algoritam primenjuje princip koji je primenjen u NSGA, tj. sortiranje nedominiranih rešenja pa se naziva NSBF. Pomoću njega je

dobijen skup najboljih Pareto rešenja za dve konfliktne funkcije cilja pri čemu je njegova robusnost najbolja u odnosu na druge MA koji su u radu primenjeni za rešavanje višeciljnog ERS problema. MA koji koristi sličan koncept kao BFA je FA. Međutim, u odnosu na BFA, FA ima više varijanti privlačnosti između agenata što dovodi do veće mobilnosti i efikasnijeg pretraživanja prostora mogućih rešenja. FA ima konceptualnu sličnost i sa PSO. U [35] se pokazuje da FA daje efikasnija rešenja multimodalnih funkcija u odnosu na PSO i da je PSO, ustvari, specijalni slučaj FA. Svici emituju sopstvenu treperavu svetlost na osnovu koje podešavaju svoje ponašanje u roju. FA idealizuje karakteristike te svetlosti primenjujući sledeća pravila: (i) svici se međusobno privlače zavisno od jačine svetlosti koju emituju; (ii) privlačnost između dva svica se definiše kao veličina srazmerna jačini svetlosti a jačina svetlosti svica se smanjuje sa povećanjem rastojanja između svitaca; (iii) jačina svetlosti svica određuje se iz funkcije cilja ili je proporcionalna funkciji cilja.

FA algoritam je u [58] uspešno primenjen za rešavanje ERS problema pri čemu su rešenja upoređena sa rešenjima drugih MA. FA je pokazao dobru efektivnost, efikasnost i robusnost pri rešavanju različitih varijanti ERS problema. U [59] se predlaže unapređeni FA za rešavanje ERS problema – adaptivni FA (eng. *Self-Adaptive FA*). Adaptivni FA primenjuje dve strategije za poboljšanje sposobnosti pretraživanja rešenja i izbegavanja lokalnih minimuma u odnosu na standardni FA. Prva strategija se bazira na informacijama o udaljenosti između svitaca i prilagođavanju koeficijenta apsorpcije svetlosti. Druga strategija je smanjivanje parametra randomozacije. Uz to, primenjuje se operacija ukrštanja za povećanje diverzifikacije potencijalnih rešenja. Adaptivni FA je testiran na šest *benchmark* funkcija i pokazao je bolje sposobnosti pretraživanja i bolje performanse u odnosu na FA. Predloženi algoritam je primenjen na tri različita sistema za rešavanje problema ERS i pri tome je dao kvalitetnija rešenja. U [60] za rešavanje ERS problema je predložen optimizacioni algoritam na bazi pretraživanja simbiotskih organizama (SOS) (eng. *Symbiotic Organisms Search*). SOS je inspirisan prirodnim sistemima u kojima se vrši interakcija između organizama. On optimizira problem polazeći od ekosistema sa organizmima koji predstavljaju kandidate rešenja. Generisanje nove populacije se vrši pomoću mutualističkih algoritamskih operatora formiranih na bazi simbiotskih odnosa između organizama. Ti operatori su: mutualizam, komensalizam i parazitizam. Pri rešavanju ERS problema predloženim

SOS, višeciljni problem je pretvoren u problem sa jednom funkcijom cilja primenom težinskog faktora. Zatim je SOS primenjen na test sistemu sa 6 generatora i više varijanti emisije štetnih gasova. Dobijeni su bolji rezultati u odnosu na rezultate drugih MA predloženih u literaturi i primenjenih na isti test sistem.

Algoritam polinacije cveta (FPA) (eng. *Flower Polination Algorithm*) [61] je još jedan MA koji je primenjen za rešavanje ERS problema [62]. FPA algoritam se bazira na procesu oprašivanja (polinaciji) cveta biljaka. Osnovni cilj pri oprašivanju cveta je da se postigne što duža postojanost cveta i da se omogući optimalan broj reprodukcija biljaka. Oprašivanje cveta biljaka se vrši kao samooprašivanje (polenom od istog cveta) ili kao unakrsno oprašivanje (polenom od cveta druge biljke). FPA sadrži sledeća četiri stepena: (i) globalno oprašivanje predstavljeno unakrsnim oprašivanjem pomoću oprašivača koji lete sledeći putanju *Levy* leta [63]; (ii) lokalno oprašivanje predstavljeno procesom samooprašivanja, bez oprašivača; (iii) održavanje postojanosti cveta od strane insekata oprašivača, koja je srazmerna sličnosti dva posmatrana cveta; (iv) interakcija između lokalnog i globalnog oprašivanja koja se proverava pomoću verovatnoće $p[0,1]$. Na bazi navedenih pravila izvedene su jednačine ažuriranja za pretraživanje prostora mogućih rešenja. FPA je u [62] primenjen za rešavanje ERS problema na šest različitih sistema sa uzimanjem u obzir efekta ventila a rezultati su upoređeni sa rezultatima različitih MA baziranih na inteligenciji jata i publikovanih u literaturi. Pokazano je da od svih razmatranih algoritama FPA daje najbolje rezultate.

Višeciljni adaptivni algoritam klonske selekcije (MOACSA) (eng. *Multi-Objective Adaptive Clonal Selection Algorithm*) je predložen i primenjen za rešavanje ERS problema u [64]. Ovaj MA se bazira na algoritmu klonske selekcije (CSA) [65]. Princip klonske selekcije je jedan od modela koji se koristi za ponašanje veštačkog imunog sistema. U njemu se imitiraju biološki principi stvaranja, proliferacije i sazrevanja klona. U MOACSA je primenjen adaptivni mehanizam sortiranja nedominiranih rešenja za dobijanje Pareto-optimalnog rešenja. Ovaj MA je primenjen za rešavanje višeciljnog ERS problema na test sistemu sa šest generatorskih jedinica i na realnom sistemu sa 10 jedinica, bez i sa neizvesnostima u opterećenju. Algoritam je pokazao dobru efikasnost a rešenja su bolja u odnosu na rešenja dobijena pomoću tri druga primenjena algoritma.

U [66] je za rešavanje ERS problema primenjen algoritam optimizacije spiralom (SOA) (eng. *Spiral Optimization Algorithm*) [67]. Ovaj MA je razvijen na bazi analogije sa fenomenom logaritamske spirale koji se javlja u prirodi i svemiru, npr., kod ciklona, tornada ili galaksija. Dobre karakteristike SOA su: mali broj varijabli, sposobnost lokalnog pretraživanja, brzo dobijanje rezultata, jednostavan proces primene, jednostavna struktura i primena procesa diverzifikacije i intenzifikacije u istom procesu. SOA je primenjen za rešavanje ERS problema sa konverzijom višeciljnog problema u problem sa jednom funkcijom cilja primenom težinskog faktora. Simulacija je izvršena za sisteme sa 3, 6 i 40 generatora i sa različitim ograničenjima i različitim oblicima funkcije cilja. Rezultati su upoređeni sa rezultatima drugih MA iz literature i pokazano je da SOA daje efikasno i kvalitetno rešenje problema ERS.

U [68] je za rešavanje ERS problema primenjen algoritam inspirisan galaksijom (GbSA) (eng. *Galaxy based Search Algorithm*) [69] koji se bazira na simuliranju spiralnih ruku spiralnih galaksija za pretraživanje prostora mogućih rešenja. Spiralno kretanje se kombinuje sa haotičnim kretanjem kako bi se izbegli lokalni optimumi. Rešenje dobijeno primenom spiralnog kretanja u pretraživačkom prostoru se dodatno podešava primenom lokalnog pretraživačkog algoritma. Dobre performanse GbSA su potvrđene pri rešavanju ERS problema na test sistemu sa tri generatora.

U [70] je za rešavanje dinamičkog ERS problema sa različitim gorivima i efektom ventila predstavljen MA pod nazivom optimizacija pretraživanjem kvazigrupe suprotnih elemenata (QOGSO) (eng. *Quasi-Oppositional Group Search Optimization*) koji se oslanja na algoritam: optimizacija pretraživanjem grupe (GSO) (eng. *Group Search Optimization*) [71]. GSO je inspirisan ponašanjem životinja u grupi. Populacija u GSO je grupa koja sadrži sledeće članove: proizvođače (članove koji traže i pronalaze hranu), pozajmljivače (članove koji uzimaju ostatke hrane od proizvođača) i lualice (rendžere) koji se kreću slučajnim putanjama. Pri svakoj iteraciji član je definisan svojom pozicijom i uglom zakretanja glave. Najbolja *fitness* vrednost je namenjena proizvođaču. Jedan broj članova grupe je randomizacijom odabran i to su pozajmljivači. Preostali članovi su lualice. Pozajmljivači vrše lokalnu pretragu oko rešenja koje je pronašao proizvođač. Lualice se nasumično kreću prostorom u cilju povećanja šanse da GSO izbegne lokalni optimum. U odnosu na GSO, algoritam QOGSO poboljšava efektivnost i kvalitet rešenja. Za populaciju sastavljenu od tačaka koje predstavljaju

potencijalna rešenja formiraju se kvazi-suprotne tačke koje su bliže ili dalje od konačnog rešenja. Ako je *fitness* vrednost (izmerena *fitness* funkcijom) posmatrane tačke veća od *fitness* vrednosti njene kvazi-suprotne tačke (za problem minimizacije), onda se posmatrana tačka zameni kvazi suprotnom tačkom. U suprotnom proces se nastavlja sa posmatranom tačkom. Na taj način se proces ubrzava.

Još jedan MA koji se bazira na ponašanju grupa životinja a koji je u [72] primenjen za rešavanje ERS problema je optimizator sivih vukova (GWO) (eng. *Grey Wolf Optimizer*) [39]. GWO je inspirisan sivim vukovima i simulira njihove društvene slojeve i mehanizam lova u prirodi. Tri glavna koraka sivih vukova u lovu su: traganje za plenom, opkoljavanje plena i napadanje plena. U lancu komandovanja sivi vukovi su poredani hijerarhijski na sledeći način: na vrhu, kao najprivilegovaniji, su alfa (α) vukovi; beta (β) vukovi su na sledećem nivou komandovanja; delta (δ) vukovi su hijerarhijski ispod prethodnih; omega (ω) vukovi su podređeni vukovima α , β i δ ali usmeravaju vukove koji su na dnu lestvice: kapa (κ) i lambda (λ) vukove. Da bi se matematički modeliralo socijalno ponašanje vukova, najbolje rešenje ocenjeno *fitness* funkcijom dodeljuje se α vuku. Drugo i treće najbolje rešenje dodeljuju se β i δ vukovima. Preostala potencijalna rešenja se dodeljuju ω , κ i λ vukovima. U GWO se optimizacija tj., lov odvija pod vođstvom α , β i δ vukova. Vukovi ω , κ i λ prate tri prethodna vuka.

U [73] je za rešavanje problema ERS primenjen KHA koji je razvijen na bazi inteligencije jata planktonskih rakova (krilova) koji plutaju okeanom. Jata planktona nemaju fizičke mogućnosti za kretanje pa plutaju okeanom pri čemu se živi organizmi u njima sporazumevaju preko specifičnih fizičkih i hemijskih procesa. Kao ciljne funkcije pri traženju rešenja uzimaju se rastojanje pojedinačnog krila do jata sa najvećom gustinom i rastojanje krila do hrane ka kojoj se jato kreće. Minimizacija troškova goriva vršena je bez razmatranja emisije gasova i sa uzimanjem u obzir efekta ventila i vrste goriva u termoelektranama.

2.2 Pregled rezultata statističke analize ponašanja MA

U prethodnom poglavlju je dat pregled velikog broja MA koji su predloženi u publikovanoj literaturi za rešavanje problema ERS. Problem ERS je rešavan za različite

moguće slučajeve u elektroenergetskom sistemu, kao što su: različit broj generatora u sistemu (mali, srednji i veliki broj generatora); minimizacija samo funkcije troškova; minimizacija samo emisije štetnih gasova; minimizacija funkcije troškova i emisije štetnih gasova, istovremeno; uzimanje ili neuzimanje u obzir veličine gubitaka u sistemu; uzimanje ili neuzimanje u obzir uticaja sekvencijalnog otvaranja ventila u termoelektrani, i dr.

U publikovanim radovima, pri izboru MA, vršeno je poređenje njihovih rezultata pri rešavanju konkretnog problema. Poređenja MA uglavnom su vršena na bazi srednjih vrednosti, najboljih vrednosti i standardne devijacije rezultata dobijenih posle većeg broja puštanja algoritma u rad za konkretnu funkciju cilja. Rezultati algoritama koji su predlagani upoređivani su, zatim, sa rezultatima drugih algoritama i na osnovu toga su izvođeni zaključci o prednosti algoritma u rešavanju određenog problema. Takva poređenja često nisu statistički utemeljena što je dovodilo do nedovoljno preciznih zaključaka. U tim radovima nije vršena primena parametarskih i neparametarskih testova za analizu ponašanja MA. Međutim, u jednom broju publikovanih radova iz oblasti statističke analize ponašanja MA pri rešavanju različitih problema računarske inteligencije predlažu se procedure zasnovane na primeni parametarskih i neparametarskih statističkih testova [74-78] na *benchmark* funkcijama. Primenom ovih procedura dobija se tačnija slika o ponašanju algoritama i o tome da li su rezultati realni ili slučajni tj. da li pripadaju određenoj populaciji koja se podvrgava statističkim zakonitostima. Zbog toga se u ovom radu predlaže primena statističke procedure na bazi parametarskih i neparametarskih testova za izbor najboljeg MA iz mnoštva predloženih, za rešavanje složenog ERS problema.

U [74] je data studija o primeni neparametarskih testova za analizu ponašanja evolucionih algoritama u rešavanju optimizacionih problema. Kao primer, uzeta je grupa evolucionih algoritama koji su predloženi na konferenciji “CEC’2005 Special Session on Real Parameter Optimization”. Studija je vršena za slučajeve primene algoritama za rešavanje pojedinačnih *benchmark* funkcija i grupe od 25 *benchmark* funkcija, istovremeno. Utvrđeno je da za ovaj primer uslovi za primenu parametarskih testova nisu ispunjeni pa je analiza vršena na bazi neparametarskih testova. Autor [75] vrši analizu i poređenje rezultata algoritama namenjenih za mašinsko učenje primenom

procedure koja obuhvata parametarske i neparametarske testove. Pri tome, analizira se grupa algoritama predloženih na konferencijama o mašinskom učenju.

U [76] se ocenjuje statistička snaga neparametarskih testova za analizu ponašanja algoritama u oblasti računarske inteligencije i predlaže postupak za primenu neparametarskih statističkih procedura pri upoređivanju algoritama kojima se rešavaju višestruki problemi (tj. veći broj problema istovremeno). Autori [77] predlažu proširenu proceduru u odnosu na [74] koju na konkretnim primerima primenjuju za analizu ponašanja optimizacionih algoritama baziranih na inteligenciji jata i evolucionih algoritama. Pri tome, koriste 25 poznatih *benchmark* funkcija. U [78] se prilikom predlaganja novog MA, algoritma inspirisanog kretanjem naelektrisanja pod dejstvom električnih i magnetnih sila (MCSS) (eng. *Magnetic Charged System Search Algorithm*), vrši poređenje ovog MA sa drugim MA, pri čemu se primenjuju statistički testovi na 18 *benchmark* funkcija.

3. MSA

MSA je predložen 2017. godine od strane Mohameda A.A. i koautora [5] i predstavlja jedan od najnovijih populacionih prirodno inspirisanih MA. Ovaj MA je razvijen na bazi simulacije leta roja noćnih leptira u potrazi za hranom, koji se orjentišu prema mesečevoj svetlosti. Roj noćnih leptira noću leti pravolinijski pri čemu koristi nebesku navigaciju - tehniku koju su u prošlosti koristili mornari pri plovidbi. To znači, da bi se kretao pravolinijski, roj leptira leti tako što zauzima pravac koji je pod stalnim uglom u odnosu na zrake mesečeve svetlosti, koji su paralelni zbog velike udaljenosti Meseca (Slika 3.1a). Pozicija roja u odnosu na Mesec se uzima kao rešenje problema koji se optimizira a kvalitet rešenja se ocenjuje na osnovu intenziteta luminescencije leptira. Pri primeni ove tehnike leptiri se sreću sa bliskim veštačkim izvorima svetlosti koji ih sputavaju i navode svojim radijalnim zracima da se kreću spiralnom putanjom oko njih, tj. da napuste svoju pravolinijsku putanju (Slika 3.1b).

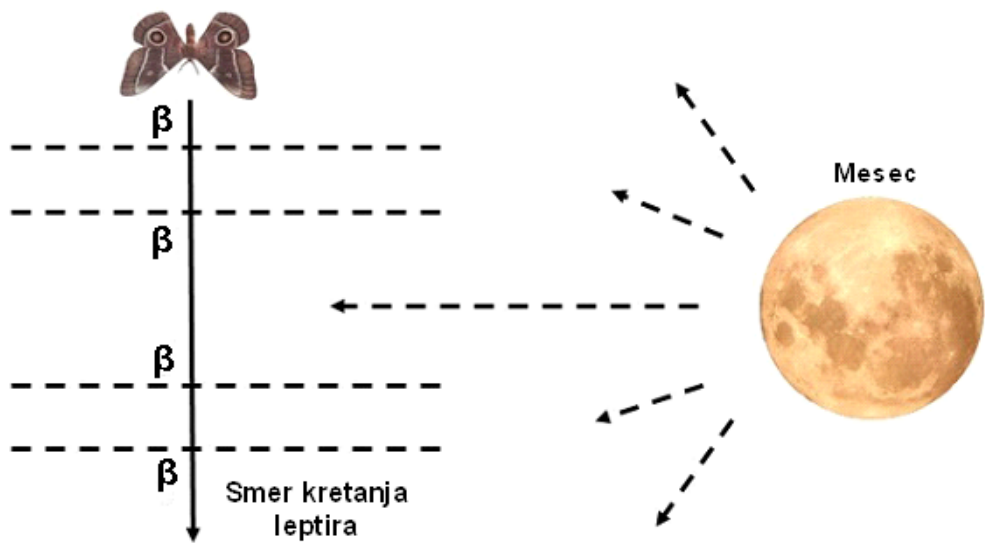
Roj se sastoji od tri grupe leptira: (i) izviđača, koji imaju sposobnost da u optimizacionom prostoru pronađu novu poziciju u odnosu na Mesec, na kojoj će svetleti i na taj način osvetljivati put roju, tj voditi roj; (ii) istraživača, koji teže da skrenu sa pravog puta i uđu u spiralnu putanju oko slučajnih bliskih izvora svetlosti koji su označeni od strane izviđača i (iii) posmatrača, koji se kreću ka najboljem globalnom rešenju (ka mesečevoj svetlosti), dobijenom od strane istraživača.

Intenzitet luminescencije pojedinačnog leptira u grupi, m_j , može se definisati fitness funkcijom $f(m_j)$. Cela grupa leptira se može podeliti, u svakoj iteraciji, na tri grupe. Prvu grupu čine izviđači, leptiri koji imaju najveći intenzitet luminescencije, tj. najbolju poziciju u jatu, u odnosu na koju se vrši ažuriranje u sledećoj iteraciji. U drugu i treću grupu se svrstavaju, prema intenzitetu luminescencije, istraživači i posmatrači.

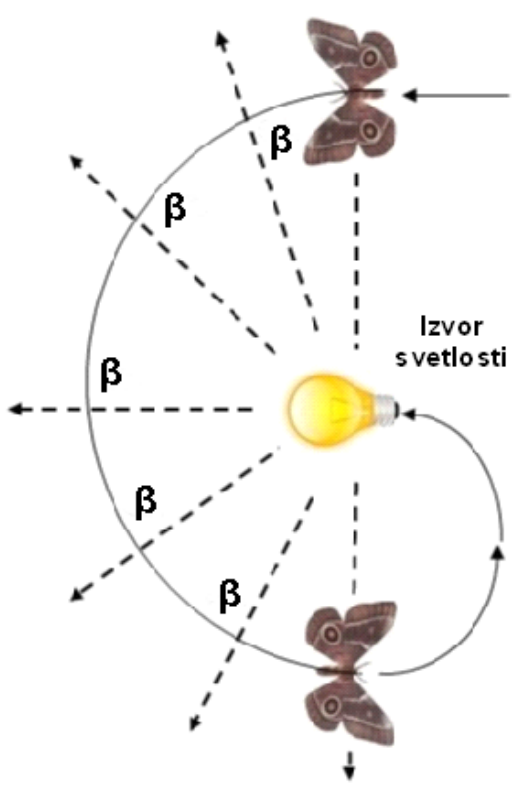
Algoritam MSA čine sledeće faze:

Faza inicijalizacije. Početne pozicije leptira (agenata pretraživanja) se definišu kao slučajne vrednosti, na sledeći način:

$$m_{jk} = rand[0,1] \cdot (m_k^{max} - m_k^{min}) + m_k^{min} \quad (3.1)$$
$$\forall j \in \{1, 2, \dots, q\}, k \in \{1, 2, \dots, d\},$$



(a)



(b)

Slika 3.1. Pravolinijsko kretanje noćnih leptira u odnosu na Mesec (a) i njihovo spiralno kretanje u odnosu na bliski izvor veštačke svetlosti (b).

gde su: d dimenzija problema, q broj jedinki u populaciju, m_k^{min} i m_k^{max} granične vrednosti. Nakon inicijalizacije, izračunavaju se *fitness* vrednosti svih leptira. Zatim se, na bazi proračunatih *fitness* vrednosti, leptiri svrstavaju u grupe.

Faza izviđanja. Tokom optimizacionog procesa može doći do prerane konvergencije, tj stagnacije procesa. Izviđači imaju zadatak da spreče ovu pojavu tako što vrše ažuriranje svoje pozicije u interakciji sa drugim leptirima primenom *Levy*-mutacije. *Levy*-mutacija se vrši prema sledećoj proceduri koja je opisana u [5], [63]: Koeficijent varijacije (relativna mera disperzije) σ_k^i izviđača u k -toj dimenziji i i -toj iteraciji izračunava se na sledeći način:

$$\sigma_k^i = \frac{\sqrt{\frac{1}{q_p} \sum_{j=1}^{q_p} (m_{jk}^i - \overline{m}_k^i)^2}}{\overline{m}_k^i} \quad (3.2)$$

gde su q_p broj izviđača a \overline{m}_k^i srednja vrednost m_k^i . Zatim se izračunava granični koeficijent varijacije μ^i na sledeći način:

$$\mu^i = \frac{1}{d} \sum_{k=1}^d \sigma_k^i \quad (3.3)$$

Izviđači koji imaju malu vrednost disperzije svrstavaju se u grupu c_p koju sačinjavaju tačke za ukrštanje,

$$k \in c_p \text{ ako je } \sigma_k^i \leq \mu^i \quad (3.4)$$

Za tačke ukrštanja $q_c \in c_p$, formiraju se sledeći vektori: *sub-trail* vektor, $\overline{a}_p = [a_{p1}, a_{p2}, \dots, a_{pq_c}]$, *host* vektor $\overline{m}_p = [m_{p1}, m_{p2}, \dots, m_{pq_c}]$ i odgovarajuće komponente donor vektora, npr., $\overline{m}_{r^1} = [m_{r^1_1}, m_{r^1_2}, \dots, m_{r^1_{q_c}}]$ [5].

Sub-trail vektor se izražava primenom *Levy*-mutacije [63], kao:

$$\begin{aligned} \overline{a}_p^i &= \overline{a}_{r^1}^i + L_{p1}^i \cdot \left(\overline{m}_{r^2}^i, -, \overline{m}_{r^3}^i \right) + L_{p2}^i \cdot \left(\overline{m}_{r^4}^i, -, \overline{m}_{r^5}^i \right), \\ \forall r^1 \neq r^2 \neq r^3 \neq r^4 \neq r^5 \neq p \in \{1, 2, \dots, q_p\} \overline{m}_{r^1}^i. \end{aligned} \quad (3.5)$$

gde su L_{p1} i L_{p2} varijable generisane pomoću *Levy*-letova [5], [63] i izraza:

$$L_p \sim \text{random}(q_c) \oplus \text{Levy}(\alpha), \quad (3.6)$$

gde su: \oplus znak za multiplikaciju; $(r^1, r^2, r^3, r^4, r^5, p)$ međusobni indeksi odabranih rešenja koja pripadaju izviđačima; $\text{Levy}(\alpha)$ slučajni hod nastao *Levy*-letom sa različitim koracima čija raspodela verovatnoće ima tzv. teški rep (eng. *heavy tail*) [5], [63]; α je indeks *Levi* α -stabilne raspodele koraka s slučajnog hoda:

$$L(s) \sim |s|^{-1-\alpha} \quad (3.7)$$

Operacija ukrštanja se vrši tako što se rešenja putanje hoda (*trail* rešenja) V_{pk}^i dobijaju na sledeći način:

$$V_{pk}^i = \begin{cases} a_{pk}^i & \text{if } k \in c_p, \\ m_{pk}^i & \text{if } k \notin c_p. \end{cases} \quad (3.8)$$

Zatim se vrši selekcija rešenja na sledeći način: Upoređuju se *fitness* vrednosti *trail* rešenja i *host* rešenja i bolje rešenje se bira za opstanak u sledećoj generaciji, tj.,

$$\overline{m}_p^{i+1} = \begin{cases} \overline{m}_p^i & \text{if } f(\overline{V}_p^i) \geq f(\overline{m}_p^i), \\ \overline{a}_p^i & \text{if } f(\overline{V}_p^i) < f(\overline{m}_p^i). \end{cases} \quad (3.9)$$

Posle toga, određuje se verovatnoća rešenja na sledeći način:

$$P_p = \frac{fit_p}{\sum_{p=1}^{q_p} fit_p}, \quad (3.10)$$

gde fit_p predstavlja intenzitet luminescencije koji se izračunava iz funkcije cilja f_p za minimizaciju problema koji se rešava:

$$fit_p = \begin{cases} \frac{1}{1+f_p} & \text{for } f_p \geq 0, \\ 1+|f_p| & \text{for } f_p < 0. \end{cases} \quad (3.11)$$

Spiralno kretanje istraživača. Leptiri koji imaju manji intenzitet luminescencije nazivaju se istraživači i njihov broj q_f se određuje na sledeći način:

$$q_f = \text{round} \left((q - q_p) \times \left(1 - \frac{i}{I} \right) \right). \quad (3.12)$$

Pozicija svakog istraživača m_j se ažurira na osnovu matematičke funkcije spiralne putanje po kojoj on leti:

$$m_j^{i+1} = |m_j^i - m_p^i| \cdot e^\theta \cdot \cos 2\pi\theta + m_p^i, \quad (3.13)$$

$$\forall p \in \{1, 2, \dots, q_p\}; j \in \{q_p + 1, q_p + 2, \dots, q_f\},$$

gde je m_p odabrano na osnovu izraza za verovatnoću P_p (3.10); $\theta \in [r, 1]$ je slučajni broj za $r = -1 - i/I$. Iz (3.13) sledi da je novo rešenje svakog istraživača bolje od trenutnog rešenja izviđača.

Kretanje posmatrača. Posmatrači imaju manji intenzitet luminiscencije i lete ka mesečevoj svetlosti. Tehnika pretraživanja posmatračkih rešenja je efikasnija nego napred objašnjena tehnika pretraživanja istraživačkih rešenja. Broj posmatrača je $q_0 = q - q_f - q_p$. Oni se klasifikuju u sledeće dve grupe: (i) posmatrači koji se kreću prema

Gausovoj raspodeli koraka (njihov broj je $q_G = \text{round}(q_0/2)$) i (ii) preostali leptiri posmatrači, čiji je broj $q_A = q_0 - q_G$, koji se kreću u skladu sa ALIM sa kratkotrajnom memorijom [5]. Jednačina ažuriranja za prvu grupu posmatrača je izvedena u skladu sa Gausovim kretanjem sa slučajnim koracima:

$$m_j^{i+1} = m_j^i + \varepsilon_1 + [\varepsilon_2 \times \text{best}_g^i - \varepsilon_3 \times m_j^i]; \forall j \in \{1, 2, \dots, q_G\},$$

$$\varepsilon_1 \sim \text{random}(\text{size}(d)) \oplus N\left(\text{best}_g^i, \frac{\log i}{i} \times (m_j^i - \text{best}_g^i)\right), \quad (3.14)$$

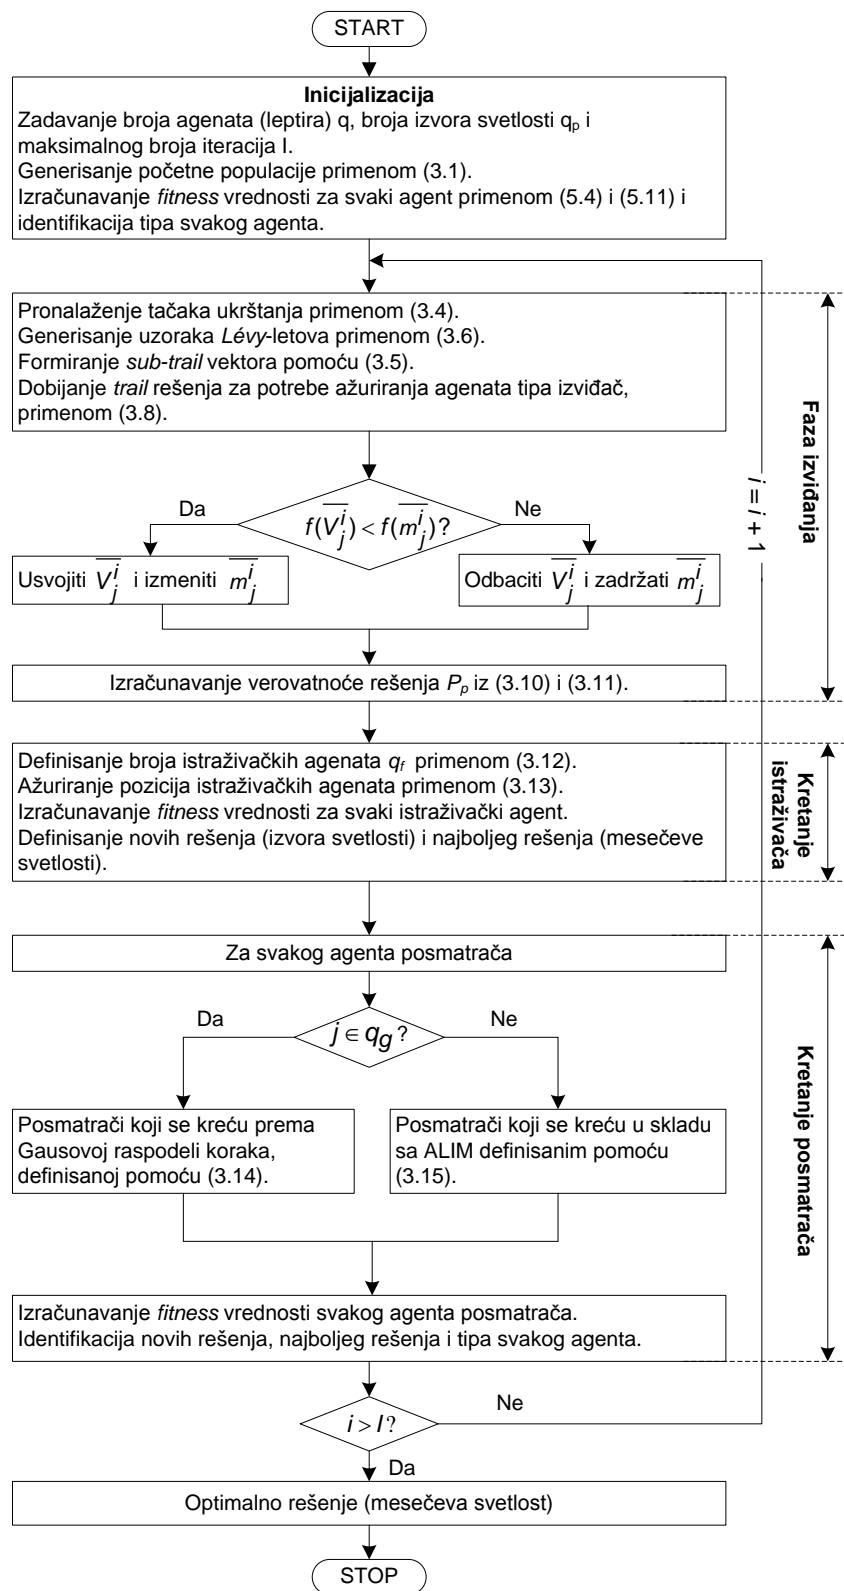
gde su: ε_1 slučajni uzorak dobijen iz Gausove (Normalne) raspodele; $\text{size}(d)$ veličina prve grupe leptira; best_g najbolje globalno rešenje dobijeno u fazi spiralnog kretanja; ε_2 i ε_3 su ravnomerno raspoređeni slučajni brojevi u intervalu $[0,1]$. Jednačina ažuriranja za drugu grupu posmatrača je napisana na osnovu ALIM sa kratkotrajnom memorijom, tj.,

$$m_j^{i+1} = m_j^i + 0.001 \cdot G \left[m_j^i - m_j^{\min}, m_j^{\max} - m_j^i \right] + (1 - g/G) \cdot r_1 \cdot$$

$$\left(\text{best}_p^i - m_j^i \right) + 2g/G \cdot r_2 \cdot \left(\text{best}_g^i - m_j^i \right); \forall j \in \{1, 2, \dots, q_A\}, \quad (3.15)$$

gde su: $1 - g/G$ kognitivni a $2g/G$ socijalni faktori; r_1 i r_2 slučajni brojevi unutar intervala $[0,1]$; best_p je izviđačko rešenje slučajno odabrano na bazi njegove vrednosti verovatnoće.

Na kraju svake iteracije poznate su *fitness* vrednosti celog roja pa se mogu redefinisati uloge svakog leptira za sledeću iteraciju. Na Slici 3.2 prikazan je dijagram toka MSA.



Slika 3.2. Dijagram toka MSA.

4. AWDO I WDO

WDO je prirodom inspirisan populacioni MA koji je opšte prihvaćen zbog dobrih osobina eksploracije i diverzifikacije. Za pretraživanje prostora mogućih rešenja WDO koristi zakon prema kojem se kreću vazdušne mase pri duvanju vetra, tj. prema kojem se svaka vazdušna parcela (kao član populacije parcela) kreće iz oblasti sa visokim vazdušnim pritiskom ka oblastima sa nižim pritiskom sve dok se ne dostigne lokacija optimalnog vazdušnog pritiska gde se pritisci parcele i lokacije izjednačuju (Slika 4.1). Brzina i pozicija svake parcele se ažuriraju u svakoj iteraciji. Ovaj iterativni process se odvija sve dok svaka vazdušna parcela ne dođe do lokacije sa optimalnim pritiskom tj. sve dok se ne postignu optimalna rešenja problema.

Izvođenje algoritma počinje tako što se formira populacija beskonačno malih parcela vazdušne mase u N -dimenzionalnom prostoru problema koji se rešava, i tim parcelama se dodeljuju slučajne brzine kretanja. Pozicije vazdušnih parcela se ažuriraju u svakoj iteraciji na osnovu fizičkih jednačina koje određuju kretanja velikih vazdušnih masa. Polazi se od Drugog Njutnovog zakon koji se primenjuje za analizu atmosferskih strujanja [79]:


$$\rho \vec{\alpha} = \sum \vec{F}_i, \quad (4.1)$$

gde su: $\vec{\alpha}$ ubrzanje, ρ gustina vazduha za parcelu kao elementarni deo vazdušne mase i \vec{F}_i sile koje deluju na elementarni deo vazdušne mase.

Iz jednačine stanja idealnog gasa dobija se izraz:

$$P = \rho RT, \quad (4.2)$$

gde su: P pritisak, R univerzalna gasna konstanta i T temperatura.



Slika 4.1. Kretanje vazdušnih masa i formiranje vetra.

Vetar je prirodna pojava koja se opisuje kao kretanje delova vazdušne mase pod dejstvom sledećih sila: sile gradijenta pritiska, (\vec{F}_{PG}), sile trenja (\vec{F}_F), gravitacione sile (\vec{F}_G) i Koriolisove sile (\vec{F}_C). Fizički izrazi ovih sila su [79]:

$$\begin{aligned}
 \vec{F}_{PG} &= -\nabla P \delta V, \\
 \vec{F}_F &= -\rho \alpha \vec{u}, \\
 \vec{F}_G &= \rho \delta V \vec{g}, \\
 \vec{F}_C &= -2\Omega \times \vec{u},
 \end{aligned}
 \tag{4.3}$$

gde su: ∇P gradijent pritiska, δV konačna zapremina vazduha, \vec{u} brzina vetra, α koeficijent trenja, \vec{g} ubrzanje zemljine teže i Ω brzina rotacije zemlje.

Kada se u gornjim jednačinama ubrzanje $\vec{\alpha}$ izrazi kao: $\vec{\alpha} = \Delta\vec{u} / \Delta t$ i ako se, radi pojednostavljenja, vremenski korak Δt odabere tako da je $\Delta t = 1$ a beskonačno mala zapreminu vazduha iznosi $\delta V = 1$, onda se kombinovanjem jednačina (4.1) do (4.3) dobija sledeća jednačina:

$$\Delta\vec{u} = \vec{g} + \left(-\nabla P \frac{RT}{P_{cur}} \right) - \alpha\vec{u} + \left(\frac{-2\Omega \times \vec{u} RT}{P_{cur}} \right) \quad (4.4)$$

gde su P_{cur} pritisak na trenutnoj lokaciji i $\Delta\vec{u}$ promena brzine.

U WDO pozicija vazdušne parcele u prostoru pretraživanja optimalnog rešenja i brzina parcele se menjaju u svakoj iteraciji. Promena brzine može biti izražena na sledeći način: $\Delta\vec{u} = \vec{u}_{new} - \vec{u}_{cur}$, gde su \vec{u}_{new} i \vec{u}_{cur} brzine u narednoj i u tekućoj iteraciji, respektivno i

$$\vec{u}_{new} = (1 - \alpha)\vec{u}_{cur} + \vec{g} + \left(-\nabla P \frac{RT}{P_{cur}} \right) + \left(\frac{-2\Omega \times \vec{u} RT}{P_{cur}} \right). \quad (4.5)$$

U WDO gravitaciona konstanta \vec{g} i gradijent pritiska ∇P se izražavaju u funkciji od pozicije \vec{x} vazdušne parcele, $\vec{g} = |g|(\vec{0} - \vec{x}_{cur})$ i $\nabla P = |P_{opt} - P_{cur}|(\vec{x}_{opt} - \vec{x}_{cur})$ [7], gde indeksi *opt* i *cur* označavaju optimalnu i tekuću vrednost. Zamenom ovih jednačina u (4.5), jednačina (4.5) se može preurediti na sledeći način:

$$\vec{u}_{new} = (1 - \alpha)\vec{u}_{cur} - g\vec{x}_{cur} + \left(\frac{RT}{P_{cur}} |P_{opt} - P_{cur}| (\vec{x}_{opt} - \vec{x}_{cur}) \right) + \left(\frac{c\vec{u}_{cur}^{other\ dim}}{P_{cur}} \right), \quad (4.6)$$

gde je uticaj Koriolisove sile zamenjen uticajem brzine, tj. $\vec{u}_{cur}^{other\ dim}$ je nova slučajno izabrana dimenzija iste vazdušne parcele [7] a c je nova konstanta ($c = -2\Omega RT$). Jednačina (4.6) može biti modifikovana zamenom veličine pritiska sa rangom parcele (koji je dobijen na bazi veličine pritiska). Ova zamena je izvršena zbog toga što u nekim slučajevima pritisak može biti ekstremno veliki zbog čega i ažurirana brzina postaje

prevelika, što može smanjiti efikasnost algoritma. Konačno, jednačina za ažuriranje brzine postaje:

$$\vec{u}_{new} = (1 - \alpha)\vec{u}_{cur} - g\vec{x}_{cur} + \left(RT \left| \frac{1}{i} - 1 \right| (\vec{x}_{opt} - \vec{x}_{cur}) \right) + \left(\frac{c\vec{u}_{cur}^{otherdim}}{i} \right), \quad (4.7)$$

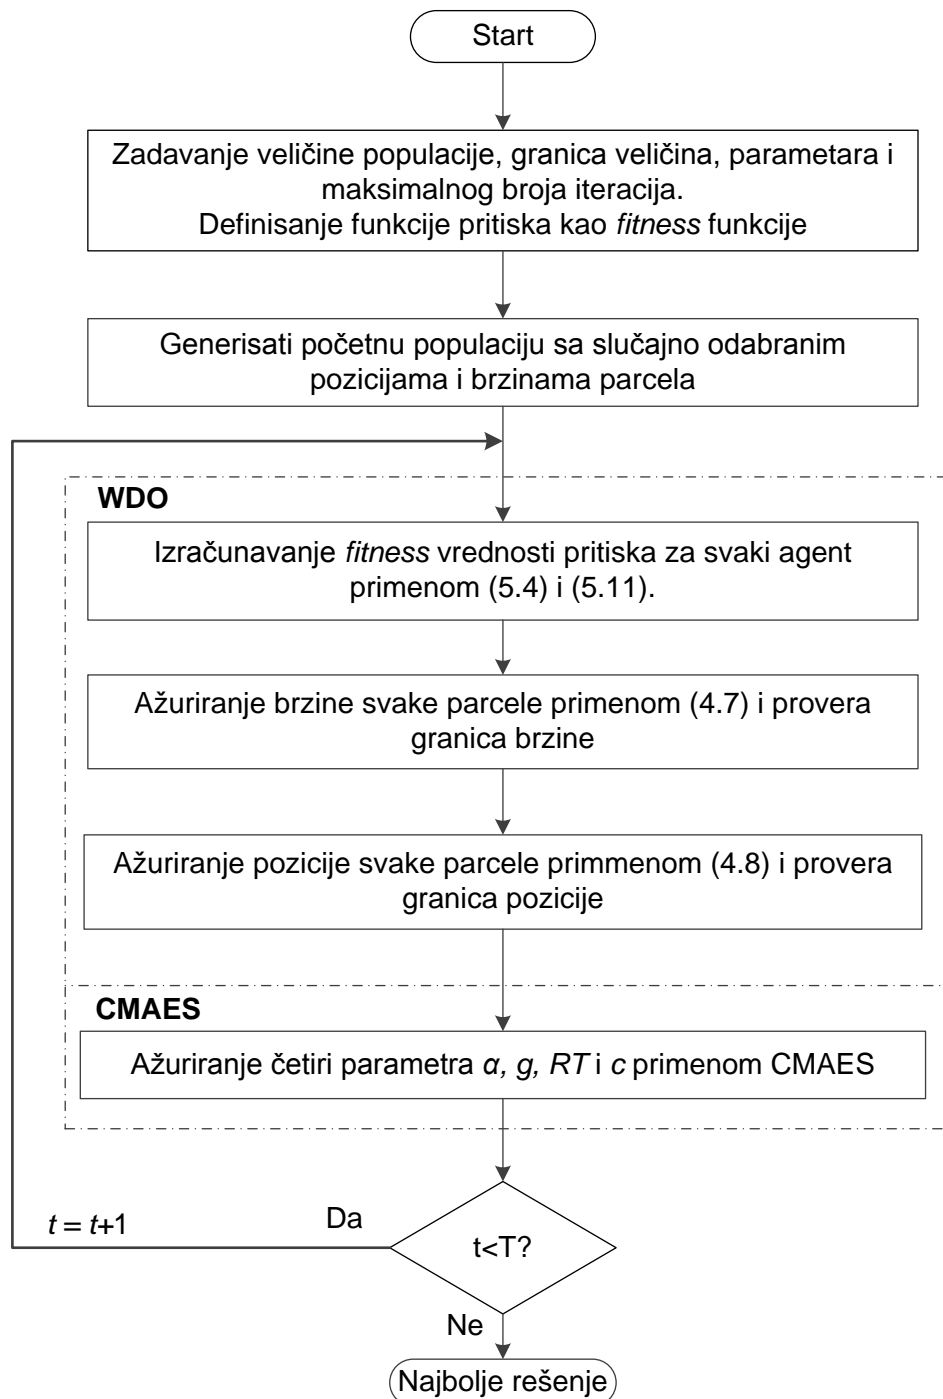
gde je vrednost P_{cur} zamenjena rangom parcele i (dobijenim na osnovu vrednosti pritiska). Posle izračunavanja \vec{u}_{new} iz (4.7) pozicija parcele može biti ažurirana primenom sledeće jednačine:

$$\vec{x}_{new} = \vec{x}_{cur} + (\vec{u}_{new}\Delta t), \quad (4.8)$$

gde su: \vec{x}_{new} pozicija u narednoj iteraciji, \vec{x}_{cur} trenutna pozicija vazdušne parcele i Δt je vremenski korak sa pretpostavljenom vrednošću $\Delta t=1$.

Pri primeni WDO korisnik podešava i zadaje parametre α , g , RT i c [7] kako bi prilagodio algoritam konkretnom problemu. U nekim slučajevima korisnik može da zada parametre nedovoljno precizno što može rezultirati smanjenjem efikasnosti algoritma. Primenom AWDO, umesto WDO, ovaj nedostatak se otklanja. AWDO je hibridni algoritam koji se sastoji od dva algoritma: WDO i CMAES. Dobre performanse AWDO algoritma su omogućene time što WDO algoritam vrši uspešno pretraživanje prostora mogućih rešenja a CMAES vrši optimizaciju parametara WDO u svakoj iteraciji. CMAES je pogodan za ovu primenu jer nije potrebno podešavanje njegovih parametara a veličina njegove populacije je ista kao kod WDO. CMAES je brz algoritam. To je još jedan razlog što je inkorporiran u AWDO, s obzirom da, generalno, dodatna optimizacija parametara, u nekim slučajevima, može usporiti algoritam. WDO započinje rad inicijalizacijom i sa slučajnim generisanjem brzina i pozicija vazdušnih parcela (kao članova populacije parcela). Sledeći korak je: evaluacija pritiska svake parcele, ažuriranje brzine i provera granice brzine. Zatim se veličine pritiska i parametara α , g , RT i c unose u CMAES. CMAES vrši optimizaciju parametara, bira nove vrednosti parametara i iste vraća u WDO. Prema tome, iterativni proces se odvija tako što WDO vrši ažuriranje pozicije i brzine a CMAES optimizira parametre. Ovaj

proces se odvija sve dotle dok se ne ispuni maksimalni broj iteracija. Na Slici 4.2 je prikazan dijagram toka AWDO.



Slika 4.2. Dijagram toka AWDO.

4.1 CMAES

CMAES spada u grupu evolucionih algoritama [8], [9]. Početna populacija se sastoji od grupe jedinki koje predstavljaju kandidate za rešenje datog optimizacionog problema. Iteracioni proces započinje izborom λ kandidata rešenja, $\mathbf{x}_i \in \mathbb{R}^N$, na osnovu multivarijantne Normalne raspodele,

$$\mathbf{x}_i = \mathcal{N}(\mathbf{m}, \sigma^2 \mathbf{C}) \quad (4.9)$$

gde je \mathbf{m} srednja vrednost raspodele, σ veličina koraka, N dimenzija problema i $\mathbf{C} \in \mathbb{R}^{N \times N}$ matrica kovarijansi. Matrica kovarijansi je matrica čiji je element na poziciji i, j kovarijansa između i -tog i j -tog elementa slučajnog vektora. Slučajni vektor predstavlja slučajnu veličinu (u ovom slučaju kandidata rešenja) sa više dimenzija. Tokom procesa reguliše se veličina koraka kako bi se izbegla prerana konvergencija i kako bi konvergencija bila brža. Matrica \mathbf{C} može biti izražena preko svojih sopstvenih vektora \mathbf{B} i sopstvenih vrednosti \mathbf{D} na sledeći način:

$$\mathbf{C} = \mathbf{B} \mathbf{D}^2 \mathbf{B}^T. \quad (4.10)$$

Posle izbora, kandidati rešenja \mathbf{x}_i se ocenjuju pomoću funkcije cilja (*fitness* funkcije) f čija se minimizacija vrši. Svi kandidati rešenja $\mathbf{x}_{i,1:\lambda}$ se razvrstavaju prema *fitness* vrednostima zatim se uzima njihov najprihvatljiviji broj μ (najčešće $\mu \approx \lambda/2$) za izračunavanje srednje vrednosti \mathbf{m} u sledećoj iteraciji ($t+1$), prema sledećem izrazu:

$$\mathbf{m}^{t+1} = \sum_{i=1}^{\mu} w_i \mathbf{x}_i^t \quad (4.11)$$

gde je w_i rekombinaciona težina i -tog najboljeg kandidata rešenja, izračunata na sledeći način:

$$w_i = \frac{\log_2(\mu + 0.5) - \log_2(i)}{\sum_{j=1}^{\mu} (\log_2(\mu + 0.5) - \log_2(j))} \quad \text{za } i = 1, 2, \dots, \mu \quad (4.12)$$

Nakon izračunavanja w_i , izračunava se efektivni broj kandidata rešenja posle rekombinacije, μ_{eff} :

$$\mu_{eff} = \left(\sum_{i=1}^{\mu} w_i^2 \right)^{-1}. \quad (4.13)$$

Posle toga, vrši se ažuriranje evolucione putanje (putanje pretraživanja) \mathbf{p}_σ i veličine koraka, prema sledećim izrazima:

$$\mathbf{p}_\sigma^{t+1} = (1 - c_\sigma) \cdot \mathbf{p}_\sigma^t + \sqrt{c_\sigma(2 - c_\sigma)} \cdot \frac{\sqrt{\mu_{eff}}}{\sigma^t} (\mathbf{C}^t)^{-1/2} (\mathbf{m}^{t+1} - \mathbf{m}^t) \quad (4.14)$$

$$\sigma^{t+1} = \sigma^t \exp \left(\frac{c_\sigma}{d_\sigma} \left(\frac{\|\mathbf{p}_\sigma^{t+1}\|}{\mathbb{E}\|\mathcal{N}(0, \mathbf{I})\|} - 1 \right) \right) \quad (4.15)$$

gde su: c_σ brzina učenja za regulaciju veličine koraka,

$$c_\sigma = \frac{\mu_{eff} + 2}{N + \mu_{eff} + 3}, \quad (4.16)$$

d_σ damping faktor za regulaciju veličine koraka,

$$d_\sigma = 1 + 2 \max \left(0, \sqrt{\frac{\mu_{eff} - 1}{N + 1}} - 1 \right) + c_\sigma \quad (4.17)$$

i $\mathbb{E}\|\mathcal{N}(0, \mathbf{I})\|$ očekivana vrednost $\|\mathbf{p}_\sigma^{t+1}\|$,

$$\mathbb{E}\|\mathcal{N}(0, \mathbf{I})\| \approx \sqrt{N} \left(1 - \frac{1}{4N} + \frac{1}{21N^2} \right). \quad (4.18)$$

Na kraju se vrši ažuriranje matrice kovarijansi, pri čemu se najpre ažurira druga evoluciona putanja \mathbf{p}_c :

$$\mathbf{p}_c^{t+1} = (1 - c_c) \cdot \mathbf{p}_c^t + \sqrt{c_c(2 - c_c)} \cdot \frac{\sqrt{\mu_{eff}}}{\sigma^t} (\mathbf{m}^{t+1} - \mathbf{m}^t) \quad (4.19)$$

$$\mathbf{C}^{t+1} = (1 - c_{cov}) \cdot \mathbf{C}^t + \frac{c_{cov}}{\mu_{eff}} \mathbf{p}_c^{t+1} (\mathbf{p}_c^{t+1})^T + \left(1 - \frac{1}{\mu_{eff}} \right) \frac{c_{cov}}{(\sigma^t)^2} \sum_{i=1}^{\mu} w_i (\mathbf{x}_i^{t+1} - \mathbf{m}^t) (\mathbf{x}_i^{t+1} - \mathbf{m}^t)^T \quad (4.20)$$

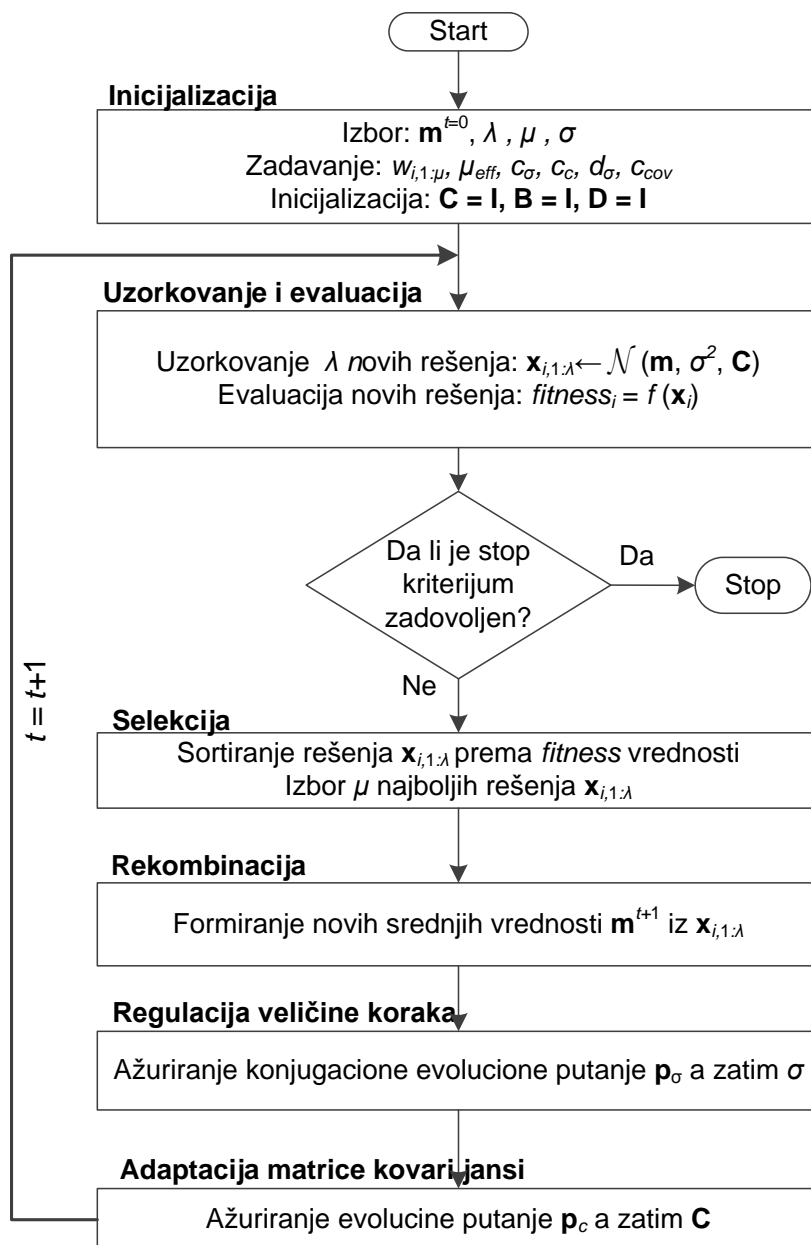
gde su: c_c brzina učenja pri ažuriranju matrice kovarijansi ranga jedan,

$$c_c = \frac{4}{N + 4} \quad (4.21)$$

i c_{cov} brzina učenja pri ažuriranju matrice kovarijansi [9],

$$c_{cov} = \frac{1}{\mu_{eff}} \frac{2}{(N + \sqrt{2})^2} + \left(1 - \frac{1}{\mu_{eff}} \right) \min \left(1, \frac{2\mu_{eff} - 1}{(N + 2)^2 + \mu_{eff}} \right). \quad (4.22)$$

Na Slici 4.3. dat je dijagram toka algoritma CMAES.



Slika 4.3. Dijagram toka CMAES.

5. MODEL ERS

Funkcija troškova goriva za pojedinačni generator g najčešće ima kvadratni oblik:

$$F_g(P_g) = a_g + b_g P_g + c_g P_g^2, \quad g = 1, 2, \dots, G \quad (5.1)$$

gde su: F_g (\$/h) – troškovi goriva generatora g , P_g (MW) - izlazna snaga generatora g a a_g , b_g i c_g koeficijenti troškova goriva generatora g . Funkcija $F_g(P_g)$ postaje ne-glatka i ne-konveksna ako se uzmu u obzir promene snage usled sekvencijalnog otvaranja ventila u termoelektrani [66]:

$$F_g(P_g) = a_g + b_g P_g + c_g P_g^2 + \left| d_g \sin\left(e_g (P_g^{\min} - P_g)\right) \right|, \quad (5.2)$$

gde su d_g and e_g koeficijenti udara usled pokretanja ventila a P_g^{\min} je minimalna snaga generatora g . Funkcija koja modelira emisiju gasova generatora u termoelektrani je zbir kvadratne i eksponencijalne funkcije izlazne snage generatora [23], [46], [50]:

$$E_g(P_g) = \alpha_g + \beta_g P_g + \eta_g P_g^2 + \xi_g \exp(\lambda_g P_g), \quad (5.3)$$

gde su: E_g (ton/h) količina emitovanih gasova generatora g , P_g (MW) izlazna snaga generatora g , i α_g , β_g , η_g , ξ_g i λ_g koeficijenti emisije generatora g .

Funkcije (5.1) i (5.2) se mogu kombinovati sa funkcijom (5.3) pri čemu se dobija zbirna funkcija [46]:

$$FE = w \sum_{g \in G} F_g(P_g) + (1-w) \gamma \sum_{g \in G} E_g(P_g) \quad (5.4)$$

u kojoj su: γ dimenzioni faktor, w težinski faktor čija vrednost se kreće u granicama $0 \leq w \leq 1$ i G ukupni broj generatora u termoelektranama, priključenih na sistem. Izborom faktora w i minimizacijom funkcije (5.4) rešava se ERS problem. Pri tome, gornja granica težinskog faktora, $w = 1$, odgovara minimizaciji samo funkcije $F_g(P_g)$, donja granica $w = 0$ odgovara minimizaciji samo funkcije $E_g(P_g)$ a druge vrednosti težinskog faktora odgovaraju istovremenoj minimizaciji troškova goriva i emisije gasova. Dimenzioni faktor γ se uvodi da bi se funkcija (5.4), koja se sastoji od dve funkcije cilja, rešavala kao funkcija sa jednim ciljem.

Minimizacija se vrši sa zadatim ograničenjima maksimalnih snaga generatora:

$$P_g^{\min} \leq P_g \leq P_g^{\max}, \quad (5.5)$$

gde su P_g^{\min} , P_g^{\max} i P_g minimalna, maksimalna i trenutna snaga generatora g , i sa zadatim uslovom balansa između proizvedene i potrošene snage:

$$\sum_{g \in G} P_g - P_D - P_{loss} = 0, \quad (5.6)$$

gde je P_D ukupna snaga potrošača a P_{loss} snaga gubitaka u prenosnom sistemu.

Gubici snage P_{loss} se izražavaju kao kvadratna funkcija trenutnih snaga generatora tj., iz Kronove formule gubitaka u elektroenergetskom sistemu [80]:

$$P_{loss} = \sum_{g \in G} \sum_{j \in G} P_g B_{gj} P_j + \sum_{g \in G} B_{0g} P_g + B_{00}, \quad (5.7)$$

gde su B_{gj} , B_{0g} koeficijenti B -loss matrice a i B_{00} konstanta.

Da bi se zadovoljila ograničenja (5.6), tokom optimizacionog procesa jedan od generatora se bira kao nezavisni (balansni) generator. Za ovaj generator (npr. generator G) vrednost izlazne snage P_G se izračunava iz sledeće jednačine:

$$P_G = P_D + P_{loss} - \sum_{g=1}^{G-1} P_g. \quad (5.8)$$

Gubici snage P_{loss} se dobijaju iz sledećih koraka: (i) zadavanje početne vrednosti $P_{loss} = P_{loss}^{(0)} = 0$ u (5.8), (ii) izražavanje vrednosti $P_G^{(0)}$ u zavisnosti od snage P_G prema (5.8) za $P_{loss} = P_{loss}^{(0)} = 0$, (iii) izračunavanje nove vrednosti gubitaka snage $P_{loss}^{(1)}$ iz (5.7), (iv) provera da li je greška manja od zadate dozvoljene greške δ , tj,

$$\left| P_{loss}^{(1)} - P_{loss}^{(0)} \right| \leq \delta \quad (5.9)$$

i (v) izražavanje vrednosti $P_G^{(1)}$ od izlazne snage P_G iz (5.8) za $P_{loss} = P_{loss}^{(1)}$. Ako je uslov (5.9) zadovoljen, ograničenje (5.6) (balans snaga) je zadovoljeno. U suprotnom, postupak se ponavlja.

Kada se vrednost P_G izračuna, potrebno je proveriti da li vrednost P_G zadovoljava ograničenje (5.5). Zatim se definiše promenljiva P_G^{lim} na sledeći način:

$$P_G^{lim} = \begin{cases} P_G^{max} & \text{if } P_G > P_G^{max}, \\ P_G^{min} & \text{if } P_G < P_G^{min}, \\ P_G & \text{if } P_G^{min} \leq P_G \leq P_G^{max}. \end{cases} \quad (5.10)$$

U (5.8) i (5.10), promenljiva P_G predstavlja zavisnu promenljivu. Posle toga, funkciji cilja FE se dodaje kvadratni penalni izraz sa penalnim faktorom λ_p i dobija se proširena funkcija cilja:

$$FE_p = FE + \lambda_p \left(P_G - P_G^{lim} \right)^2 \quad (5.11)$$

koja se minimizira.

6. METODOLOGIJA REŠAVANJA ERS PROBLEMA PRIMENOM MSA I AWDO

6.1 Formiranje opšteg dijagrama toka

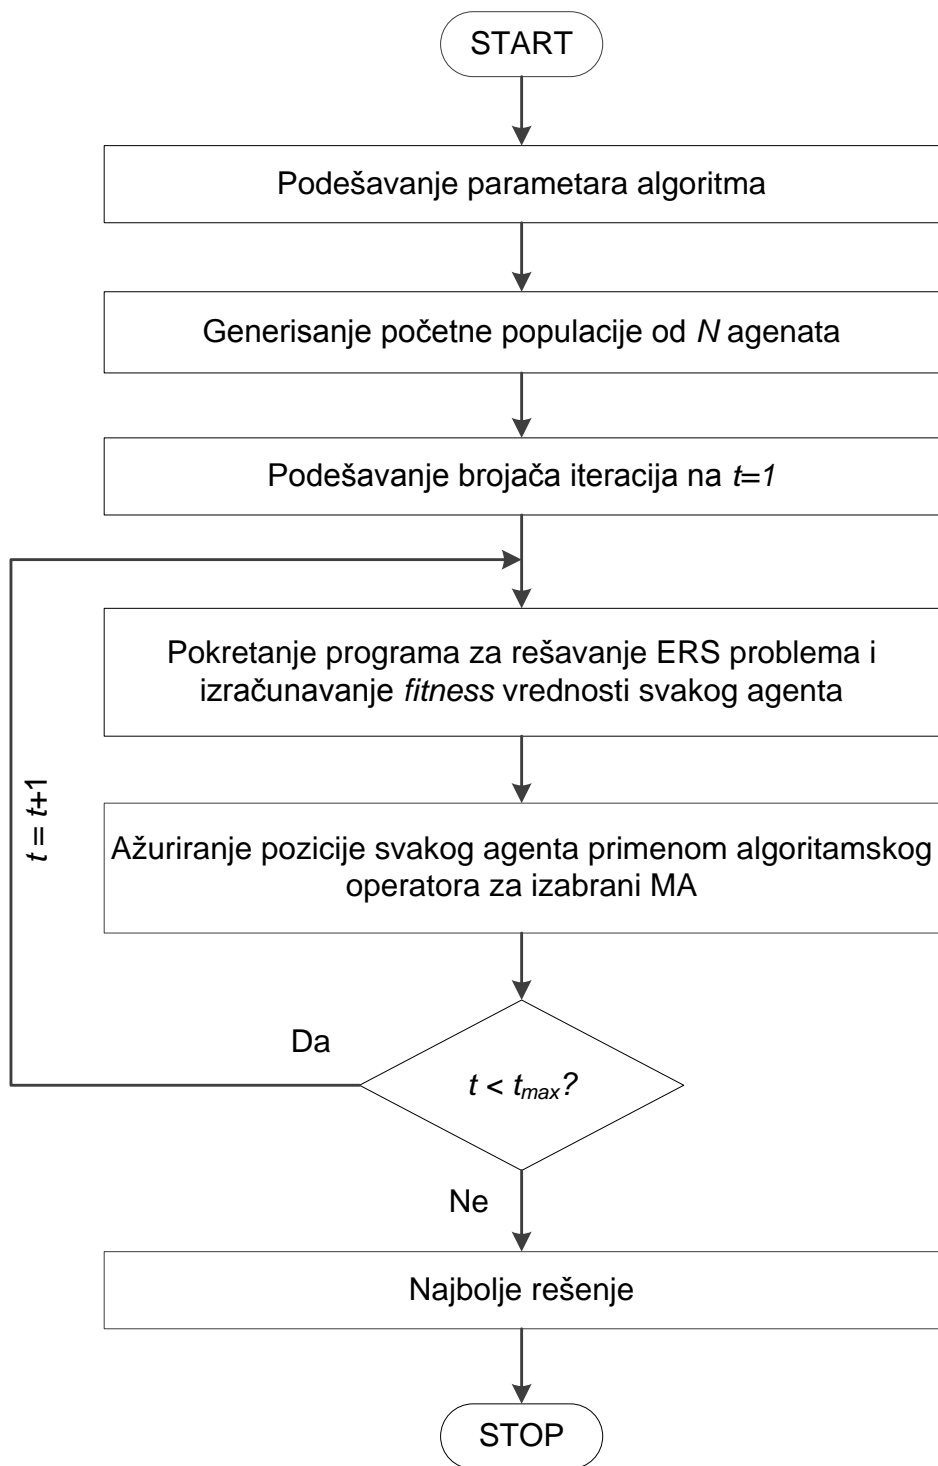
Generalno, pri rešavanju nekog problema primenom populacionog MA definišu se pretraživački agenti koji su predstavljeni vektorom njihove pozicije \mathbf{X}_i u pretraživačkom prostoru. U slučaju rešavanja ERS problema, elementi ovog vektora su izlazne snage generatora P_i^g izuzimajući snagu balansnog generatora G . U sistemu sa N pretraživačkih agenata, pozicija i -tog agenta je onda definisana na sledeći način:

$$\mathbf{X}_i = [P_i^1, \dots, P_i^g, \dots, P_i^{G-1}] \quad \text{za } i = 1, 2, \dots, N \quad (6.1)$$

Uopšteni dijagram toka za rešavanje ERS problema primenom MA dat je na Slici 6.1.

6.2 Formiranje koraka MSA i AWDO

Na osnovu opisa algoritama MSA i AWDO, datih u glavama 3 i 4, dijagrama toka prikazanih na Slikama 3.2 i 4.3 i opšteg dijagrama toka za rešavanje ERS problema primenom MA datog na Slici 6.1, mogu se formulirati koraci pri implementaciji ovih algoritama za rešavanje konkretnog problema ERS. Tabele 6.1 i 6.2 prikazuju ove korake prema redosledu izvršavanja.



Slika 6.1. Opšti dijagram toka za rešavanje ERS problema primenom MA.

Tabela 6.1. Koraci pri rešavanju ERS problema primenom MSA.

Inicijalizacija	
Korak 1	Identifikacija prostora pretraživanja. Inicijalizacija parametara MSA: veličine populacije q , broja svetlosnih izvora q_p i maksimalnog broja iteracija .
Korak 2	Generisanje početne populacije primenom (3.1). Početna pozicija svakog agenta se bira slučajno kao jedna vrednost između minimalne i maksimalne vrednosti upravljačkih veličina (izlaznih snaga generatora).
Korak 3	Izračunavanje izlazne snage balansnog generatora za svaki agent u tekućoj populaciji.
Korak 4	Izračunavanje fitness vrednosti za svaki agent primenom (5.4) i (5.11) i identifikacija tipa svakog agenta.
Faza izviđanja	
Korak 5	Pronalaženje tačaka ukrštanja primenom (3.4).
Korak 6	Generisanje uzoraka <i>Levy</i> -letova primenom (3.6).
Korak 7	Formiranje sub-trail vektora pomoću (3.5).
Korak 8	Dobijanje trail rešenja za potrebe ažuriranja agenata tipa izviđač, primenom (3.8).
Korak 9	Vršenje selekcija rešenja na sledeći način: Upoređuju se fitness vrednosti trail rešenja i host rešenja a bolje rešenje se bira za opstanak u sledećoj generaciji (3.9).
Korak 10	Izračunavanje verovatnoće rešenja P_p iz (3.10) i (3.11).
Faza spiralnog kretanja istraživačkih agenata	
Korak 11	Definisanje broja istraživačkih agenata q_f primenom (3.12).
Korak 12	Ažuriranje pozicija istraživačkih agenata primenom (3.13).

Korak 13	Izračunavanje fitness vrednosti za svaki istraživački agent.
Korak 14	Definisanje novih rešenja (novih izvora svetlosti) i najboljeg rešenja (mesečeve svetlosti).

Faza kretanja agenata posmatrača pomoću navigacije

Korak 15	Agenti posmatrači se klasifikuju u dve grupe: posmatračke koji se kreću prema Gausovoj raspodeli koraka i preostale posmatračke koji se kreću u skladu sa ALIM.
Korak 16	Izračunavanje fitness vrednosti svakog agenta posmatrača.
Korak 17	Identifikacija novih rešenja, najboljeg rešenja i tipa svakog agenta.
Korak 18	Ponavljjanje koraka 3 – 17 sve dok nije ispunjen kriterijum za zaustavljanje (unapred definisani broj iteracija).
Korak 19	Prikazivanje najboljeg rešenja i zaustavljanje (Stop).

Tabela 6.2. Koraci pri rešavanju ERS problema primenom AWDO.

Korak 1	Identifikacija prostora pretraživanja. Inicijalizacija koeficijenata, veličine populacije, granica veličina i maksimalnog broja iteracija . Definisanje funkcije pritiska kao <i>fitness</i> funkcije.
Korak 2	Inicijalizacija: Generisanje početne populacije preko početne brzine i početne pozicije svakog agenta (vazdušne parcele), koje se biraju slučajno kao vrednosti između zadatih granica. Pozicija agenta predstavlja upravljачku veličinu, tj., izlaznu snagu generatora.
Korak 3	Izračunavanje izlazne snage balansnog generatora za svaki agent u tekućoj populaciji.
Korak 4	Izračunavanje <i>fitness</i> vrednosti pritiska za svaki agent primenom (5.4) i (5.11).
Korak 5	Ažuriranje brzine primenom (4.7) i proveru granica brzine.

Korak 6	Ažuriranje pozicije primenom (4.8) i provera granica pozicije.
Korak 7	Ažuriranje četiri koeficijenta: α , g , RT i c primenom CMAES.
Korak 8	Ponavljjanje koraka 3 – 7 sve dok se ne ispuni kriterijum za zaustavljanje (unapred definisani broj iteracija).
Korak 9	Prikazivanje najboljeg rešenja i zaustavljanje (Stop).

6.3 Proširenje modela ERS

Iz (5.7) sledi da se udeo pojedinačnog generatora u ukupnim gubicima u sistemu može izračunati na sledeći način:

$$P_{loss,g} = P_g \sum_{j \in G} B_{gj} P_j + B_{0g} P_g + B_{00} / G. \quad (6.2)$$

Prema tome, snaga jednog generatora $P_{s,g}$ koja se predaje tržištu, određuje se na sledeći način:

$$P_{s,g} = P_g - P_{loss,g} \quad (6.3)$$

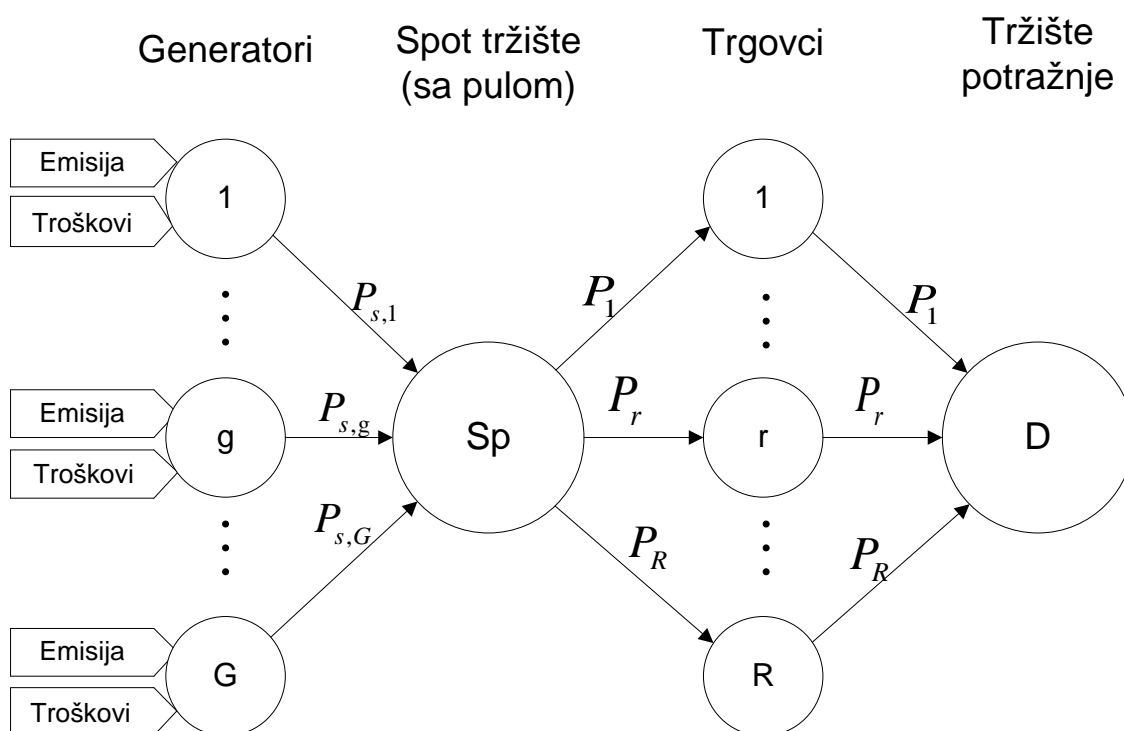
Primenom izraza (6.2) i (6.3) model ERS može se povezati sa modelima tržišta električne energije, tj., mogu se razmatrati performanse tržišta električne energije uzimajući u obzir ERS.

6.4 Objedinjeni model: ERS - lanac snabdevanja električnom energijom

U ovom poglavlju se izvodi model lanca snabdevanja na spot tržištu električne energije, koji se integriše sa modelom ERS. To je balansni model lanca snabdevanja tržišta sa centralizovanim pulom za balansiranje proizvodnje i potrošnje i trenutnom prodajom (kupovinom). Balansni model lanca snabdevanja karakteriše se optimalnim

uslovima za sve učesnike koji se nadmeću u njemu na konkurentan način prema konceptu Neša (Nash) [18]. Optimalni uslovi se dobijaju iz Nešove ravnoteže koja se izvodi za dati lanac snabdevanja. Na tržištu električne energije spot strukture električna energije se prodaje i kupuje na spot tržištu trenutno (sada, odmah) po trenutnoj (spot) ceni. Glavne funkcije pula su: utvrđivanje cene usluga i usklađivanje fleksibilne proizvodnje i potrošnje električne energije kako bi se osigurala stabilnost sistema.

Na Slici 6.2 je prikazana šema prema kojoj se razvija model lanca snabdevanja koji se integriše sa modelom ERS. Šema se sastoji od većeg broja nivoa idući od proizvođača ka potrošačima. Pojedinačni generatori su označeni sa g i nalaze se na prvom nivou. Ukupan broj generator je G . Na drugom nivou je spot tržište, S_p , a na trećem trgovci, r . Ukupno je R trgovaca. Na četvrtom nivou se nalaze kupci električne energije sa potražnjom, D . Trgovci kupuju električnu energiju na spot tržištu i istu prodaju potrošačima. Blokovi “troškovi” i “emisija” u šemi označavaju da se u modelu



Slika 6.2. Šema za razvoj modela lanca snabdevanja na tržištu električne energije spot strukture.

lanca snabdevanja uzimaju u obzir minimalni troškovi goriva i količine emitovanih gasova, dobijeni rešavanjem ERS problema. Troškovi goriva u termoelektranama predstavljaju najveći trošak proizvodnje. Prema [78] oni iznose 96% ukupnih troškova proizvodnje. Preostali troškovi proizvodnje (rad, material i održavanje) predstavljaju fiksne procenete u odnosu na troškove goriva [77]. Između pojedinačnog generatora g i spot tržišta, S_p , vrši se transakcija proizvedene snage $P_{s,g}$ (6.3). Trgovac r kupuje količinu snage P_r sa spot tržišta po utvrđenoj zajedničkoj ceni s i istu prodaje potrošačima D po potrošačkoj ceni d . Balansni uslov na spot tržištu je:

$$\sum_g^G P_{s,g} = \sum_r^R P_r \quad (6.4)$$

Snaga je izražena u MW a cene i profiti u \$/h. Snaga P_r trgovca r se dobija maksimizacijom profita trgovca. Profit trgovca Π_r se može izraziti na sledeći način:

$$\Pi_r = dP_r - sP_r = (d - s)P_r, \quad r = 1, \dots, R \quad (6.5)$$

U modelu koji se ovde izvodi prodajna cena d se izražava kao linearna inverzna funkcija snaga P_r . Ova funkcija predstavlja tzv. agregatnu funkciju potražnje i njen oblik je isti kao u [79], [80]:

$$d = \kappa - \sum_r^R \varphi_r P_r, \quad \kappa \geq 0, \quad \varphi_r \geq 0, \quad r = 1, \dots, R \quad (6.6)$$

gde je φ_r različito za svakog prodavca i predstavlja nagib funkcije potražnje (krive potražnje) kod prodavca r . Parametri κ i φ_r se u praksi procenjuju iz aproksimativne krive potražnje i na osnovu udela svakog trgovca na ukupnom tržištu. Procedura aproksimacije krive potražnje i dobijanje njenih parametara κ i φ_r detaljno su opisani u [79]. Veličina spot cene s se dobija kada se prvi izvod od (6.5) izjednači sa nulom (Nešova ravnoteža) tj. iz uslova da svaki trgovac maksimizira svoj profit Π_r :

$$\frac{\partial \Pi_r}{\partial P_r} = \frac{\partial d}{\partial P_r} P_r + d - s = 0, \quad r = 1, \dots, R \quad (6.7)$$

Iz (6.6) i (6.7) sledi:

$$s = -\varphi_r P_r + \kappa - \sum_r^R \varphi_r P_r, \quad r = 1, \dots, R \quad (6.8)$$

Sumiranjem levih i desnih strana svih R jednačina (6.8) i izražavanjem s , dobija se:

$$s = -\frac{R+1}{R} \sum_r^R \varphi_r P_r + \kappa, \quad r = 1, \dots, R \quad (6.9)$$

Izražavanjem sume $\sum_r^R \varphi_r P_r$ iz (6.9) i uvrštavanjem dobijenog izraza u (6.8), izraz za dobijanje veličine snage P_r trgovca r dobija se na sledeći način:

$$P_r = \frac{\kappa - s}{(R+1)\varphi_r} \quad (6.10)$$

Sumiranjem R jednačina (6.10) i uzimanjem u obzir (6.4), dobija se konačan izraz za izračunavanje spot cene s :

$$s = \kappa - \frac{R+1}{\sum_r^R \frac{1}{\varphi_r}} \sum_s^G P_{s,g} \quad (6.11)$$

Iz (6.5) suma profita svih R trgovaca je:

$$\sum_r^R \Pi_r = (d - s) \sum_r^R P_r, \quad r = 1, \dots, R \quad (6.12)$$

Profit generatora g se izračunava na sledeći način:

$$\Pi_g = P_{s,g}s - F_g, \quad g = 1, \dots, G \quad (6.13)$$

a ukupan profit svih generatora G je:

$$\sum_g^G \Pi_g = s \sum_g^G P_{s,g} - \sum_g^G F_g, \quad g = 1, \dots, G \quad (6.14)$$

Na osnovu dobijenih izraza u ovoj glavi, može se formulirati sledeća procedura za izračunavanje optimalnih tokova snaga, cena i maksimalnih profita u lancu snabdevanja, minimizirajući troškove goriva i/ili količinu emitovanih gasova (korišćenjem ERS modela): (i) za svaki generator izračunati količinu izlazne snage $P_{s,g}$ koja se prodaje na spot tržištu, korišćenjem ERS modela i odgovarajućeg MA (u ovom radu, AWDO); (ii) izračunati spot cenu s snage, primenom formule (6.11) za zadatu funkciju potražnje (6.6); (iii) za svakog trgovca izračunati P_r primenom formule (6.10); (iv) izračunati potrošačku cenu d snage korišćenjem izraza za funkciju potražnje (6.6); (v) izračunati maksimalne vrednosti profita generatora, trgovaca i ukupni profit lanca snabdevanja $(\sum_r^R \Pi_r + \sum_g^G \Pi_g)$; (vi) analizirati rezultate za različite slučajeve minimizacije (troškova goriva, emisije gasova i istovremeno troškova goriva i emisije gasova).

7. REZULTATI TESTIRANJA MSA I AWDO

Algoritmi MSA i AWDO su za rešavanje problema ERS testirani na dva standardna IEEE test sistemima od kojih jedan sadrži 3 generatora a drugi 6. Ovi test sistemi su korišćeni za rešavanje ERS problema i u slučajevima primene drugih MA predloženih u literaturi. Da bi se izvršilo poređenje rezultata, u ovoj glavi se, zajedno sa MSA i AWDO, vrši implementacija algoritama PSO GSA i FA koji su već ranije predloženi u literaturi za rešavanje problema ERS. Takođe, rezultati se upoređuju i sa rezultatima drugih algoritama datih u publikovanim radovima. MSA, AWDO, PSO GSA i FA se realizuju primenom MATLAB 2011b softvera, na personalnom računaru sa 2,20 GHz i 3,0 GB RAM memorije. Najbolji rezultati svakog algoritma pri simulacijama dobijeni su nakon 30 puštanja algoritma u rad. Tolerancija greške pri proračunu je $\delta = 10^{-6}$ MW. *B-loss* matrice sistema su date u Tabeli A1. Vrši se minimizacija troškova goriva, minimizacija emisije gasova ili minimizacija troškova goriva i emisije gasova istovremeno. Pri tome, odgovarajuće funkcije cilja su dobijene iz zbirne funkcije cilja (2.41) kada se u njoj težinski faktor zada sa vrednostima: $w = 1$, $w = 0$ ili $w = 0,5$.

7.1 Rezultati testiranja MSA

Testiranje algoritma MSA je izvršeno na dva test sistema. Kao test sistem 1 uzet je standardni IEEE test sistem sa 6 generatora i 30 čvorova i sa ukupnom snagom potrošnje od 283,4 MW. U ovom test sistemu se ne uzima u obzir efekat otvaranja ventila u termoelektranama a emisija NO_x gasova je obuhvaćena optimizacijom. Da bi se rezultati mogli upoređivati sa rezultatima dobijenim u literaturi primenom drugih MA, razmatrana su dva slučaja test sistema 1: Slučaj I u kome se ne uzimaju u obzir gubici snage u sistemu i Slučaj II u kome se gubici snage u sistemu uzimaju u obzir. Parametri algoritama, koji su podešeni za simulacije, dati su u Tabeli 7.1. Koeficijenti troškova goriva i koeficijenti emisije gasova koji se javljaju u (2.38) – (2.40) preuzeti su iz [46] i dati su Tabeli A2. Usvojeni dimenzioni faktor γ_{NO_x} iznosi 1000 (\$/ton). U Tabeli 7.2 data su najbolja dobijena rešenja za izlazne snage generatora, troškove goriva i emisiju NO_x gasova u termoelektranama za test sistem 1.

Test sistem 2 sadrži 3 generatora sa snagom potrošnje 850 MW i emisijom NO_x i SO_x gasova. Za ovaj sistem koeficijenti troškova goriva i emisije NO_x i SO_x gasova su preuzeti iz [66] (Tabela A3). U ovom slučaju, dimenzioni faktori koji se javljaju u (2.41) su uzeti iz [23] i oni iznose: $\gamma_{\text{NO}_x} = 147582.78814$ (\$/ton) – pri minimizaciji emisije gasova NO_x i $\gamma_{\text{SO}_x} = 970.031569$ (\$/ton) – pri minimizaciji emisije gasova SO_x. Test sistem 2 je bez gubitaka snage. Tabela 7.3 prikazuje minimalne i maksimalne vrednosti i standardne devijacije za slučajeve primene MSA, PSO GSA i FA na test sistemu 2. Iz Tabele 7.3 sledi da su minimalne vrednosti troškova goriva kao i minimalne vrednosti emisije, jednake za sva tri algoritma. Međutim, standardne devijacije u slučaju primene MSA su daleko manje u odnosu na standardne devijacije druga dva algoritma (manje su za 3 do 4 reda veličina). U nastavku, u Tabeli 7.4 data su najbolja rešenja za izlazne snage generatora, troškove goriva i emisije za test sistem 2, koja su dobijena primenom MSA pri $w = 0$, $w = 1$ i $w = 0,5$. Rezultati dobijeni u ovom radu pomoću MSA i FA za test sistem 1, zajedno sa odgovarajućim rezultatima dobijenim u publikovanoj literaturi, dobijenim pomoću drugih algoritama (uključujući i PSO GSA) sumirani su u Tabeli 7.5. Kao što se vidi iz Tabele 7.5, MSA i FA daju bolje vrednosti minimalnih troškova goriva u odnosu na vrednosti dobijene algoritmima koji su predloženi u [56], [66], [81], [42] i [44] dok su te vrednosti iste ili vrlo bliske vrednostima dobijenim pomoću algoritama u [53] i [21]. Minimalne vrednosti emisije NO_x gasova izračunate primenom MSA i FA su iste ili bolje nego odgovarajuće vrednosti dobijene u [56], [42], [53], [44], [21] i [81]. Tabela 7.5, takođe, pokazuje da je uticaj gubitaka snage u sistemu, P_{loss} , na vrednosti minimalnih troškova goriva i emisije gasova vrlo mali ili zanemarljiv. Na Slici 7.1 su prikazani profili konvergencije za MSA, FA i PSO GSA, koji se dobijaju pri minimizaciji troškova goriva i emisije gasova za test sisteme 1 i 2. Sa Slike 7.1 se vidi da MSA konvergira ka minimalnoj vrednosti kroz broj iteracija koji je manji nego u slučaju PSO GSA. U odnosu na FA, MSA konvergira kroz broj iteracija koji je manji (Slika 7.1b) ili približno isti (Slika 7.1a i 7.1c). Za sva tri algoritma početna brzina konvergencije je velika.

Tabela 7.1. Podešeni parametri algoritama za primenu u test sistemima 1 i 2.

	MSA			FA					PSOGSA					
	N	T	N_c	N	T	A	β_{\min}	Γ	N	T	G_0	A	C_1	C_2
1	50	200	6	50	200	0.25	0,2	1	50	200	1	10	2	2
2	50	200	6	50	200	0.25	0,2	1	30	50	100	10	2	2

Tabela 7.2. Najbolja rešenja dobijena primenom algoritma MSA za test sistem 1.

	Slučaj I			Slučaj II		
	$w = 1$	$w = 0$	$w = 0.5$	$w = 1$	$w = 0$	$w = 0.5$
P_1 (MW)	10,97171	40,60695	23,23182	12,09514	41,09296	22,55436
P_2 (MW)	29,97533	45,90863	36,03847	28,62855	46,36389	35,45494
P_3 (MW)	52,42618	53,79580	53,88271	58,35710	54,43888	57,00613
P_4 (MW)	101,62733	38,29380	74,57153	99,28234	39,04004	74,54195
P_5 (MW)	52,42481	53,78922	53,88031	52,40076	54,44660	54,81962
P_6 (MW)	35,97464	51,00560	41,79515	35,19223	51,55068	41,55569
Troškovi (\$/h)	600,11141	638,27583	606,80105	605,99837	646,20486	612,25190
Emisija NO_x (ton/h)	0,22215	0,19420	0,20329	0,220728	0,194179	0,203571
Gubici P_{loss} (MW)	-	-	-	2,55612	3,53304	2,53268

Tabela 7.3. Minimalne i maksimalne vrednosti i standardne devijacije rezultata dobijenih primenom algoritama MSA, FA i PSO GSA za test sistem 2.

Algoritam		MSA	FA	PSOGSA
Minimizacija troškova goriva ($w = 1$)	Min	8194,35612	8194,35612	8194,35612
	Max	8194,35612	8194,35612	8194,35612
	Std.dev	4,00e-12	1,37e-9	2,38e-8
Minimizacija NO_x emisije	Min	0,096738	0,097338	0,095138

(w = 0)	Max	0,096738	0,096738	0,095138
	Std.dev	1,14e-15	1,80e-12	2,93e-12
Minimizacija SO _x emisije (w = 0,5)	Min	8,820849	8,820849	8,820849
	Max	8,820849	8,820849	8,820849
	Std.dev	8,73e-16	1,13e-12	1,80e-11

Tabela 7.4. Najbolja rešenja dobijena primenom algoritma MSA za test sistem 2.


	Minimizacija troškova goriva (w = 1)	Minimizacija emisije NO _x (w = 0)	Minimizacija emisije SO _x (w = 0)	Minimizacija troškova i emis. (w = 0.5)
P ₁ (MW)	393,16983	542,61947	542,61947	495,33897
P ₂ (MW)	334,60376	227,39222	227,39221	249,88672
P ₃ (MW)	122,22641	79,98831	79,98832	104,77431
Troškovi (\$/h)	8194,35612	8260,14181	8260,14182	8226,05250
Emisija NO _x	0,099677	0,096738	0,096738	0,095143
Emisija SO _x	8,891854	8,820849	8,820849	8,828920

7.1.1 Zaključak


U ovoj glavi se po prvi put testira algoritam MSA za rešavanje problema ERS. Ovaj algoritam je jedan od najnovijih MA koji je predložen za rešavanje složenih problema. Algoritam je ovde uspešno testiran na dva standardna IEEE test sistema sa 3 i 6 generatora, bez uzimanja u obzir efekta otvaranja ventila u termoelektranama. Komparativni rezultati dobijeni primenom MSA, FA i PSO GSA su pokazali da je standardna devijacija rezultata najmanja u slučaju primene MSA (vrednosti su u granicama od $4 \cdot 10^{-12}$, pri minimizaciji troškova goriva, do $8,73 \cdot 10^{-6}$, pri minimizaciji emisije SO_x gasova) što govori o tome da MSA ima najveću robusnost među tri algoritma koja se testiraju na konkretnim test sistemima. Osim toga, primenom MSA dobijaju se minimalne vrednosti troškova goriva i emisije NO_x gasova, koje su jednake

Tabela 7.5. Poređenja najboljih rešenja za troškove goriva i emisiju NO_x gasova za test sistem 1.

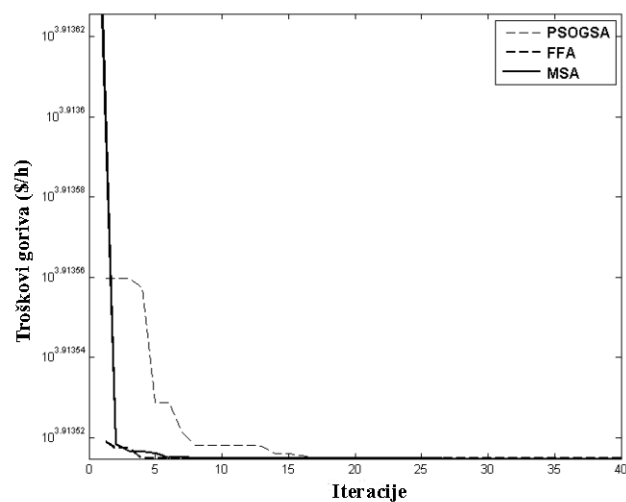
Algoritam	Slučaj I						Slučaj II					
	Minimizaj troškova goriva ($w = 1$)		Minimizaj emisije NO _x gasova ($w = 0$)		Minimizacija troškova i emisije NO _x gasova ($w = 0.5$)		Minimizaj troškova goriva ($w = 1$)		Minimizaj emisije NO _x gasova ($w = 0$)		Minimizacija troškova i emisije NO _x gasova ($w = 0.5$)	
	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)
MSA	600,11141	0,22215	638,27583	0,194203	606,80105	0,20329	605,99837	0,220728	646,20486	0,194179	612,25190	0,203571
FA	600,11141	0,22214	638,27398	0,194203	606,79835	0,20329	605,99837	0,220728	646,20731	0,194179	612,25302	0,203570
PSOGSA[53]	600,11141	0,22215	638,27452	0,194203	606,79841	0,20329	605,99837	0,220728	646,20838	0,194179	612,25222	0,203571
MBFA [56]	600,17	0,2200	636,73	0,1942	610,906	0,2000	607,6700	0,2198	644,4300	0,1942	616,496	0,2002
SOA [66]	600,986	0,20889	640,749	0,18729	624,604	0,18708	-	-	-	-	-	-
PSO[84]	600,13	0,2199	636,62	0,1943	-	-	607,8400	0,2192	642,9000	0,1942	-	-
MOPSO [42]	600,12	0,2216	637,42	0,1942	608,65	0,2017	607,7900	0,2193	644,7400	0,1942	615,000	0,2021
DE [21]	600,1114	0,2221	638,2907	0,1942	-	-	608,0658	0,2193	645,0850	0,1942	-	-
MODE/PSO [44]	600,115	0,22201	638,270	0,194203	-	-	606,0073	0,2209	646,0243	0,1942	-	-



(a)



(b)



(c)

Slika 7.1. Uporedne krive konvergencije algoritama MSA, PSO GSA i FA u slučajevima minimizacije: (a) emisije NO_x gasova za test sistem 1 bez P_{loss} ; (b) emisije SO_x gasova za test sistem 2 i (c) troškova goriva za test sistem 2.

odgovarajućim vrednostima dobijenim primenom FA i PSO GSA. Ove minimalne vrednosti su bolje nego odgovarajuće vrednosti dobijene u publikovanoj literaturi primenom drugih MA na istom test sistemu. To govori o tome da su rešenja dobijena primenom MSA visokog kvaliteta. Profili konvergencije funkcija cilja dobijeni primenom MSA, FA i PSO GSA imaju velike početne brzine ali MSA daje optimalno rešenje posle najmanjeg broja iteracija. To znači da MSA ima najbolje konvergentne osobine. Konačno, poređenjem profila konvergencije, standardnih devijacija i optimalnih vrednosti rezultata dobijenih u ovom poglavlju i u publikovanoj literaturi pokazano je da MSA ima najbolju efektivnost i robusnost pri rešavanju ERS problema u IEEE test sistemima sa 3 i sa 6 generatora, koji se razmatraju bez uticaja otvaranja ventila u termoelektranama. U narednom poglavlju MSA će biti testiran, zajedno sa AWDO i drugim algoritmima, za rešavanje ERS problema sa složenijim funkcijama cilja, tj., uzimanjem u obzir uticaja ventila u termoelektranama na rezultate optimizacije.

7.2 Rezultati testiranja AWDO

Drugi algoritam koji se predlaže u ovom radu za rešavanje ERS problema je AWDO. To je hibridni algoritam kome su hibridizacijom poboljšane performanse. AWDO se, takođe kao i MSA, testira na standardnom IEEE test sistemu sa 6 generatora, 30 čvorova, ukupnom snagom potrošača od 283,4 MW i sa emisijom NO_x gasova. Međutim, u ovom slučaju se uzima u obzir efekat ventila u sistemu čime funkcija cilja postaje složenija. Rezultati dobijeni pomoću AWDO se upoređuju sa rezultatima implementacije MSA, PSO GSA i FA, koji se, takođe, dobijaju u ovom poglavlju. PSO GSA je odabran za poređenje sa MSA i AWDO zbog toga što je u [53] pokazao najbolje performanse u odnosu na rezultate prezentovane u literaturi za rešavanje ERS problema. Parametri algoritama koji su podešeni za simulaciju dati su u Tabeli 7.6. Testiranje se vrši za dva slučaja ERS problema: (i) bez uzimanja u obzir efekta ventila u termoelektranama (Slučaj I) i (ii) sa uzimanjem u obzir efekta ventila (Slučaj II). Gubici snage u elektroenergetskom sistemu su razmatrani u oba slučaja. Pri ovom testiranju usvojeni dimenzioni faktor iznosi $\gamma_{\text{NO}_x} = 1000$ (\$/ton). Minimizacija se vrši sa tri vrednosti težinskog faktora u funkciji cilja (5.4): $w = 1$ (minimizacija troškova goriva), $w = 0$ (minimizacija emisije gasova) i $w = 0,5$ (minimizacija troškova goriva i emisije gasova, istovremeno). U Tabeli 7.7 date su maksimalne i minimalne vrednosti i standardne devijacije dobijene primenom AWDO, MSA, FA i PSO GSA na test sistem (Slučaj I). Iz Tabele 7.7 sledi da su dobijene minimalne vrednosti za troškove goriva i emisiju gasova jednake za sve algoritme. Međutim, standardne devijacije rezultata dobijenih primenom AWDO su mnogo manje nego standardne devijacije dobijene primenom ostala tri algoritma (kreću se od $1.2372e-11$ – pri minimizaciji troškova goriva do $3.6654e-13$ – pri minimizaciji emisije gasova).

Najbolja rešenja za izlazne snage generatora, troškove goriva i emisiju gasova, dobijena primenom AWDO, data su u Tabeli 7.8. Na Slici 7.2 su prikazane karakteristike konvergencije algoritma AWDO koji se testira i implementiranih algoritama MSA, FA i PSO GSA, pri minimizaciji troškova goriva uz uvažavanje efekta ventila (Slučaj II). Sa Slike 7.2 se vidi da su početne brzine opadanja karakteristika konvergencije velike za sve algoritme što pokazuje da svi algoritmi imaju dobru konvergenciju. Međutim, AWDO dostiže optimalno rešenje posle manjeg broja iteracija

nego ostala tri algoritma. To znači da AWDO ima bolju konvergenciju od MSA, FA i PSO GSA.

U Tabeli 7.9 se vrši poređenje najboljih rešenja za troškove goriva i emisiju NO_x gasova, dobijenih primenom AWDO, MSA, FA i PSO GSA za slučaj uticaja ventila na troškove (Slučaj II). Iz Tabele 7.9 sledi da AWDO daje najbolje rezultate za minimalne troškove i jednake vrednosti minimalnih emisija gasova kao ostala tri algoritma. Iz rezultata u Tabeli 7.9 sledi da je vrednost troškova goriva, dobijena primenom AWDO, za 0.0529 \$/h manja nego vrednost dobijena primenom MSA, za 0.0163 \$/h manja nego vrednost dobijena primenom PSO GSA i za 0.0370 \$/h manja nego vrednost dobijena primenom FA. Prema tome, primena AWDO može dati bolji ekonomski efekat nego ostala tri algoritma. Niži troškovi goriva (Tabela 7.9) i manja standardna devijacija (Tabela 7.7) vrednosti veličina koje se ocenjuju pokazuju da su rešenja dobijena primenom AWDO kvalitetnija nego rešenja dobijena pomoću MSA, FA i PSO GSA. U Tabeli 7.10 su rezultati dobijeni pomoću AWDO za test sistem (Slučaj I) sumirani i upoređeni sa raspoloživim rezultatima u publikovanoj literaturi. Iz Tabele 7.10 se vidi da AWDO daje bolje rezultate za minimalne troškove goriva nego algoritmi predloženi u [21], [42], [44], [56] i [81] i jednake rezultate kao algoritam MSA predložen u ovom radu i algoritam PSO GSA predložen u [53]. Minimalne vrednosti emisije NO_x gasova, izračunate pomoću AWDO, su jednake sa odgovarajućim vrednostima dobijenim pomoću MSA (u ovom radu) i pomoću PSO GSA [53] a bolje su od odgovarajućih vrednosti dobijenih pomoću algoritama predloženih u [21], [42], [44], [56] i [81].

Slučajnost je jedna od osobina stohastičkih MA s obzirom da se inicijalizacija populacije vrši slučajnim izborom brojeva. U Tabeli 7.11 su date frekvencije dostizanja vrednosti troškova goriva u različitim iteracionim rangovima posle 30 puštanja algoritma AWDO za Slučaj II. Iz Tabele 7.11 može se videti da je AWDO robustan i najkonzistentniji algoritam u odnosu na ostala tri razmatrana algoritma.

Tabela 7.6. Podešeni parametri algoritama koji su primenjeni na test sistemu.

AWDO			MSA			FA					PSO GSA					
N	T	α, g, RT, c	N	T	N_c	N	T	A	β_{min}	γ	N	T	G_0	A	C_1	C_2
50	200	optimizirani	50	200	6	50	200	0,25	0,2	1	50	200	1	10	2	2

Tabela 7.7. Minimalne vrednosti, maksimalne vrednosti i standardne devijacije rezultata i vreme izvršavanja iteracija, dobijeni primenom algoritama: AWDO, MSA, PSO GSA i FA za primenjeni test sistem (Slučaj I).

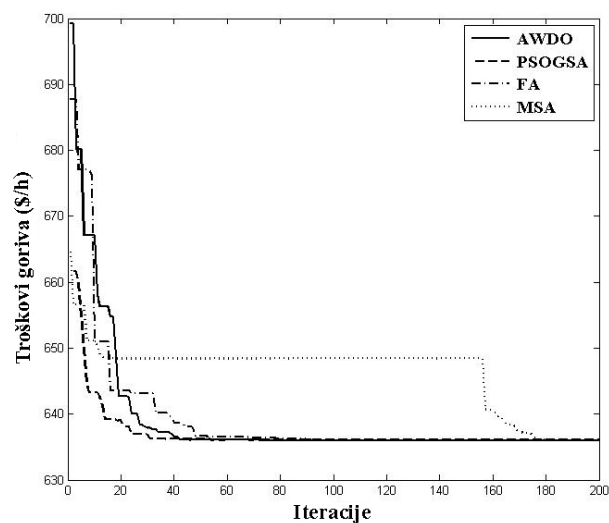
Algoritam		AWDO	MSA	PSOGSA	FA
Minimizacija pri $w = 1$	Minimalna vrednost	605,99837	605,99837	605,99837	605,99837
	Maksimalna vrednost	605,99840	605,99841	643,19300	606,40143
	Standardna devijacija	1,2372e-11	9,2426e-06	13,9840	0,0736
	Vreme iteracija (s)	4,64440	6,37231	3,09460	7,17510
Minimizacija pri $w = 0$	Minimalna vrednost	0,194179	0,194179	0,222654	0,194179
	Maksimalna vrednost	0,194179	0,194179	0,194179	0,194179
	Standardna devijacija	3,6654e-13	2,2373e-06	6,3959	1,1483e-05
	Vreme iteracija (s)	6,84278	8,47069	2,86218	8,79489
Minimizacija pri $w = 0,5$	Standardna devijacija	2,74563-11	2,4235e-06	8,6575	6,9793e-08
	Vreme iteracija (s)	5,35274	7,07522	3,12065	7,70115

Tabela 7.8. Najbolja rešenja dobijena primenom algoritma AWDO.

	Slučaj I			Slučaj II		
	$w = 1$	$w = 0$	$w = 0.5$	$w = 1$	$w = 0$	$w = 0.5$
P_1 (MW)	12,09691	41,09250	22,55426	5,00000	41,09250	5,00000
P_2 (MW)	28,63120	46,36678	35,45564	11,77284	46,36678	18,61854
P_3 (MW)	58,35573	54,44194	57,00525	83,53981	54,44194	80,05706
P_4 (MW)	99,28542	39,03737	74,53983	74,81557	39,03737	74,81317
P_5 (MW)	52,39702	54,44590	54,82118	79,79983	54,44590	77,91437
P_6 (MW)	35,18992	51,54851	41,55653	30,35130	51,54851	28,95097
Troškovi gor. (\$/h)	605,99837	646,20700	612,25279	635,82242	728,66748	638,92308
NO _x (ton/h)	0,220729	0,194179	0,203570	0,226734	0,194179	0,222780
P_{loss} (MW)	2,55619	3,53300	2,53270	1,87934	3,53300	1,95412
Vreme iteracije (s)	4,6444	6,8428	5,3527	7,3134	6,9214	5,8684

Tabela 7.9. Poređenja najboljih rešenja za test sistem (Slučaj II) dobijenih primenom algoritama AWDO, MSA, PSO GSA i FA.

Algo- ritam	Optimizacija pri $w = 1$				Optimizacija pri $w = 0$				Optimizacija pri $w = 0,5$			
	Troškovi (\$/h)	Emisija (ton/h)	P_{loss} (MW)	Iteraciono vreme (s)	Troškovi (\$/h)	Emisija (ton/h)	P_{loss} (MW)	Iteraciono vreme (s)	Troškovi (\$/h)	Emisija (ton/h)	P_{loss} (MW)	Iteraciono vreme (s)
AWDO	635,82242	0,226734	1,87934	7,3134	728,66748	0,194179	3,53300	6,9214	638,92308	0,222780	1,95412	5,8684
MSA	635,87530	0,226533	1,88236	2,1015	728,66962	0,194179	3,53298	2,0852	639,11337	0,222607	1,96232	1,8408
PSOGSA	635,83871	0,226902	1,87969	3,3096	728,66748	0,194179	3,53300	3,3583	639,11517	0,222590	1,96127	3,4931
FA	635,85945	0,227061	1,87763	7,3957	728,66693	0,194179	3,53295	8,7980	638,79420	0,222911	1,95048	7,4486



Slika 7.2. Komparativne karakteristike konvergencije za algoritme AWDO, MSA, FA i PSO GSA u slučaju minimizacije troškova goriva sa uticajem otvaranja ventila u termoelektrani.

Tabela 7.10. Poređenja najboljih rešenja za troškove goriva i emisiju NO_x gasova, dobijenih u ovom radu i u publikovanoj literaturi za test sistem (Slučaj I).

Algoritam	Optimizacija pri $w = 1$		Optimizacija pri $w = 0$		Optimizacija pri $w = 0.5$	
	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)	Troškovi (\$/h)	Emisija (ton/h)
AWDO	605,99837	0,220729	646,20700	0,194179	612,25279	0,203570
MSA	605,99837	0,220728	646,20486	0,194179	612,25190	0,203571
PSOGSA [53]	605,99837	0,220728	646,20838	0,194179	612,25222	0,203571
FA	605,99837	0,220728	646,20731	0,194179	612,25302	0,203570
MBFA [56]	607,6700	0,2198	644,4300	0,1942	616,496	0,2002
MOPSO [42]	607,7900	0,2193	644,7400	0,1942	615,000	0,2021
PSO [81]	607,8400	0,2192	642,9000	0,1942	-	-
DE [21]	608,0658	0,2193	645,0850	0,1942	-	-
MODE/PSO [44]	606,0073	0,2209	646,0243	0,1942	-	-

Tabela 7.11. Frekvencija konvergencije troškova goriva za Slučaj II, posle 30 puštanja algoritma u rad.

Opseg iteracija	AWDO	MSA	PSOGSA	FA
0-10	0	7	12	2
10-20	1	3	9	2
20-30	2	1	2	0
30-50	27	0	1	9
5-100	0	0	3	17
100-200	0	19	3	0

7.2.1 Zaključak

U ovom poglavlju je izvršeno testiranje hibridnog algoritma AWDO za rešavanje problema ERS sa funkcijama koje sadrže nelinearnosti zbog uticaja otvaranja ventila u termoelektranama i zbog uvrštavanja u njima izraza za minimizaciju gubitaka u sistemu. To je još jedan MA, pored prethodno testiranog MSA, koji je predložen zadnjih godina za rešavanje različitih problema. Glavna prednost algoritma AWDO je što je to adaptivni algoritam koji optimizira svoje parametre u svakoj iteraciji i time poboljšava proces globalnog pretraživanja rešenja. Pri testiranju AWDO, višeciljni ERS problem je pretvoren u problem sa jednom funkcijom cilja primenom težinskog faktora. AWDO je testiran na IEEE test sistemu sa 6 generatora i 30 čvorova. Testiranje je vršeno za različite moguće varijante rešavanja ERS problema: (i) optimizacija samo troškova goriva; (ii) optimizacija samo emisije zagađujućih gasova; (iii) optimizacija troškova goriva i emisije gasova, istovremeno; (iv) bez uticaja otvaranja ventila u termoelektranama; (v) sa uticajem otvaranja ventila. U svim ovim slučajevima uzimani su u obzir gubici snage u sistemu. Zajedno sa AWDO, na ovom test primeru testirana su još tri algoritma: MSA i FA koji su u prethodnom poglavlju testirani na test primerima sa manje složenim funkcijama cilja i PSOGSA koji je već ranije u [53] predložen za rešavanje problema ERS. Ovi algoritmi su odabrani zbog toga što su pokazali bolje performanse u odnosu na ranije predložene MA u literaturi za rešavanje ERS problema.

Rezultati simulacije pokazuju da AWDO daje najbolje rezultate za troškove goriva i iste vrednosti minimalne emisije gasova u odnosu na ostala tri primenjena algoritma. Zbog toga, AWDO može dati i najbolje ekonomske efekte. Standardna devijacija rezultata je mnogo manja u slučaju primene AWDO nego u slučajevima sa ostalim algoritmima. AWDO daje optimalne vrednosti rešenja posle manjeg broja iteracija nego ostala tri algoritma, što pokazuje da ima bolju osobinu konvergencije. Na osnovu svega navedenog, može se reći da su poređenja dobijenih konačnih rezultata, profila konvergencije, i statističkih podataka rezultata pokazala da AWDO ima izuzetno dobre osobine robusnosti, efektivnosti i efikasnosti koje ga čine boljim algoritmom od svih do sada predloženih MA za rešavanje ERS problema sa složenim funkcijama koje sadrže nelinearnosti izazvane efektom ventila i gubicima snage u sistemu.

8. REZULTATI REŠAVANJA PROBLEMA: ERS - LANAC SNABDEVANJA

U ovoj glavi je predloženi integrisani model ERS i lanca snabdevanja primenjen za proračun tokova snaga, cena i profita u lancu snabdevanja. Sistem se sastoji od IEEE test elektroenergetskog sistema sa 6 generatora, spot tržišta električne energije, četiri trgovačke kompanije i potrošača. Izlazne snage generatora, smanjene za gubitke u sistemu, se predaju lancu snabdevanja a zajednički pružalac usluge prenosa je dostupan svakom trgovcu. Oblik krive potražnje (6.6) je isti kao u [79] i njeni parametri su u ovom slučaju: $\kappa = 330$, $\varphi_1 = 0,4570$, $\varphi_2 = 0,6855$, $\varphi_3 = 0,7426$, $\varphi_4 = 0,9711$. Cena na spot tržištu je izražena u \$/h. Tabela 8.1 daje vrednosti snaga $P_{s,g}$ generatora, koje su dobijene primenom algoritma AWDO minimiziranjem: troškova goriva ($w = 1$), količine emitovanih gasova ($w = 0$) troškova goriva i količine emitovanih gasova istovremeno ($w = 0,5$). Vrednost $P_{s,g}$ za svaki generator je dobijena smanjenjem vrednosti ukupne izlazne snage generatora za vrednost $P_{loss,g}$ (6.3). Vrednosti troškova i profita generatora su date u Tabeli 8.2. Vrednosti snaga P_r i profita Π_r trgovaca su date u Tabeli 8.3.

Tabela 8.1. Količine snaga čija transakcija se vrši sa generatora ka spot tržištu.

W	Snage čija transakcija se vrši sa generatora ka spot tržištu, $P_{s,g}$, (MW)						
	$P_{s,1}$	$P_{s,2}$	$P_{s,3}$	$P_{s,4}$	$P_{s,5}$	$P_{s,6}$	ΣP_s
1	5,01518	11,62726	83,44629	74,03373	79,19164	30,08590	283,4
0	39,72800	45,51234	54,47292	38,78117	54,15277	50,75280	283,4
0,5	5,02603	18,33580	80,01382	74,02160	77,31030	28,69245	283,4

Tabela 8.2. Troškovi i profit generatora.

W	(\$/h)	Generator, g						
		1	2	3	4	5	6	Σ
1	Troškovi	20,25000	33,39503	198,28726	118,40107	189,11173	76,37733	635,82242

	Profit	454,93315	1068,27590	7708,16293	6896,21874	7314,21475	2774,23077	26216,03624
0	Troškovi	126,57464	121,34871	142,70822	70,17168	141,23144	126,63279	728,66748
	Profit	3637,61125	4190,89872	5018,54495	3604,30430	4989,68785	4682,14283	26123,19117
0.5	Troškovi	20,25000	50,00302	191,68328	118,39523	185,55685	73,03470	638,92308
	Profit	455,96117	1687,29518	7389,54391	6895,07527	7139,51460	2645,54544	26212,93558

Tabela 8.3. Snage i profit trgovaca.

Trgovac, r	1	2	3	4	Σ
Snaga, P_r (MW)	102,95450	68,63633	63,35875	48,45042	283,40000
Profit, Π_r (&/h)	4844,030301	3229,353534	2981,042078	2279,602355	13334,028268

8.1 Zaključak

U ovoj glavi je ERS model povezan sa modelom lanca snabdevanja na deregulisanom tržištu električne energije spot strukture sa centralizovanim pulom za balansiranje proizvodnje i potrošnje električne energije. Ovakav objedinjeni model i u radu predložena procedura proračuna su primenjeni za proračun tokova snaga na tržištu električne energije i cena električne energije uzimajući u obzir minimalne troškove goriva i emisiju štetnih gasova (rešavanjem ERS problema) zajedno sa maksimalnim profitom učesnika u lancu snabdevanja (postavljanjem *Nash*-ove ravnoteže). Za ove proračune izvedena je *Nash*-ova ravnoteža u lancu snabdevanja sa ERS. Predloženi objedinjeni model je primenjen na primeru u kome je IEEE test sistem sa 6 generatora povezan sa lancem snabdevanja tržišta električne energije spot strukture. Ovakav postupak se može primeniti pri upravljanju tržištem električne energije i višekriterijumskom donošenju odluka od strane učesnika u lancu snabdevanja, uzimajući u obzir troškove i emisiju štetnih gasova u termoelektranama i maksimalni profit učesnika u lancu snabdevanja.

9. REZULTATI STATISTIČKE ANALIZE PONAŠANJA MSA I AWDO

U ovoj glavi izvršena je statistička analiza rezultata četiri napred razmatrana MA pri rešavanju ERS problema primenom test sistema. Vršena je minimizacija osam funkcija navedenih u Tabeli 9.1, kojima se opisuje ERS problem. Elektroenergetski sistem u kome se ERS problem rešava je standardni IEEE test sistem sa 30 čvorova i 6 generatora, koji napaja potrošače ukupne snage od 283,4 MW. Matrice gubitaka sistema (*B-loss* matrice) i koeficijenti emisije i troškova goriva su uzeti iz [46]. Algoritam je realizovan u računarskom okruženju MATLAB 2011b na personalnom računaru sa 2,2 GHz i 3,0 GB RAM memorije. Parametri jednačina ažuriranja, koje se koriste pri simulaciji, su pažljivo podešeni i dati su u Tabeli 7.6. Za AWDO nije potrebno vršiti podešavanje parametara pošto on optimizira parametre u svakoj iteraciji. Rezultati simulacije su dobijani nakon 30 puštanja algoritma u rad. U Tabeli 9.2 su date vrednosti dobijenih minimalnih i srednjih vrednosti, standardnih devijacija i srednje procentualne greške za sva četiri algoritma i svih osam funkcija. Procentualna greška pojedinačnog rezultata je izračunavana u odnosu na najbolju vrednost. Srednja procentualna greška je izračunavana kao srednja vrednost procentualnih grešaka za svaku funkciju. Srednja procentualna greška je uzeta kao mera za ocenu performansi svakog algoritma [11]. Statistička analiza ponašanja MA u ovom radu je izvršena primenom sledećih statističkih testova:

1. testovi normalnosti: *Kolmogorov-Smirnov* test, *Shapiro-Wilk* test i *D'Agostino-Pearson* test, koji su primenjeni na rezultatima dobijenim za svaku funkciju posebno;
2. *Levenov (Levene)* test homogenosti;
3. upareni *t* - test i *Wilcoxon-ov* test primenjeni na rezultatima dobijenim za svaku funkciju posebno;
4. testovi normalnosti: *Kolmogorov-Smirnov* test, *Shapiro-Wilk* test i *D'Agostino-Pearson* test, koji su primenjeni na rezultate dobijene za sve funkcije, istovremeno;
5. *Wilcoxon-ov* i *Friedman-ov* neparametarski testovi za analizu ponašanja MA za

sve funkcije, istovremeno.

Statistička analiza u ovom radu je vršena primenom softverskog paketa SPSS.

9.1 Primena statističkih testova za pojedinačne funkcije

Na početku su primenjeni testovi normalnosti i homogenosti kako bi se utvrdilo da li je moguće primeniti parametarske statističke testove za analizu ponašanja algoritama pri rešavanju ERS problema. Primenjena su tri testa normalnosti: test *Kolmogorov-Smirnov*, koji upoređuje raspodelu verovatnoće rezultata dobijenih na uzorku primenom algoritma, sa Gausovom raspodelom; test *Shapiro-Wilk* koji izračunava stepen simetrije i *kurtosis* (koeficijent homogenosti) krive raspodele i *D'Agostino-Pearson* test koji izračunava *kurtosis* i *skewness* (koeficijent asimetrije) u odnosu na očekivanu Gausovu raspodelu. U Tabeli 9.3 su date vrednosti verovatnoća (p -vrednosti) testova normalnosti primenjenih na rezultate dobijene primenom algoritama. U ovom radu usvojeno je da nivo značajnosti p -vrednosti iznosi $\alpha = 0,05$. Iz Tabele 9.3 je očigledno da su sve p -vrednosti manje od nivoa značajnosti α , osim u slučaju primene PSOGSA na funkcijama f5 – f8 gde su p - vrednosti veće od 0,05. To znači da se uzorački rezultati algoritama AWDO, MSA i FA ne podvrgavaju normalnoj raspodeli dok se rezultati algoritma PSOGSA podvrgavaju normalnoj raspodeli pri njegovoj primeni na funkcijama f5 – f8. Ako bi uzorak bio veći od primenjenog, moglo bi se očekivati da se PSOGSA podvrgava normalnoj raspodeli za sve funkcije. Histogrami i Q-Q grafici (grafičke prezentacije kvantila dobijenih iz rezultata i kvantila dobijenih iz normalne raspodele) za algoritme AWDO, MSA, PSOGSA i FA prikazani su na Slici 9.1 i potvrđuju zaključak o normalnosti dobijen iz testova normalnosti. Rezultati Levenovog testa pokazuju za svaku funkciju da uzoračke varijanse algoritama nisu homogene (p -vrednosti su manje od nivoa značajnosti od 0,05 za sve funkcije). Odavde sledi zaključak da postoje razlike u varijansama raspodela četiri algoritma koja se testiraju, za svaku od osam funkcija. Pošto uslovi normalnosti (za većinu funkcija) i homogenosti (za sve funkcije) nisu potvrđeni primenjenim testovima, zaključuje se da parametarski testovi nisu pouzdani za dalju analizu. Zbog toga se u nastavku za analizu rezultata pojedinačnih funkcija primenjuju neparametarski testovi. Najpre se primenjuje *Wilcoxon* test za upoređivanje u parovima. *Wilcoxon* test je analiza značajnosti razlike

Tabela 9.1. Opis ERS funkcija koje se minimiziraju.

	Funkcija	Opis funkcije
f1	$F(P_g) = \sum_{g \in G} (a_g + b_g P_g + c_g P_g^2), \quad g = 1, 2, \dots, G$	$F(P_g)$ je funkcija troškova goriva za svaki generator u termoelektranama (\$/h); P_g je izlazna snaga generatora g (MW); G je ukupni broj generatora; a_g , b_g i c_g su koeficijenti troškova.
f2	$E(P_g) = \sum_{g \in G} (\alpha_g + \beta_g P_g + \eta_g P_g^2 + \xi_g \exp(\lambda_g P_g))$	$E(P_g)$ je funkcija emisije gasova za svaki generator u termoelektranama (t/h); α_g , β_g , η_g , ξ_g i λ_g su koeficijenti emisije generatorskih jedinica g .
f3	$FE(P_g) = F(P_g) + \gamma E(P_g)$	$FE(P_g)$ je zbirna funkcija troškova goriva i količine emitovanih gasova generatora g ; γ je dimenzioni faktor.
f4	$F_{loss}(P_g) = F(P_g) + \lambda_p (P_g - P_G^{\lim})^2$	$F_{loss}(P_g)$ je funkcija koja se sastoji od zbira $F(P_g)$ i kvadratnog izraza sa penalnim faktorom, koji zavisi od gubitaka snage u sistemu; λ_p je penalni faktor.
f5	$FE_{loss}(P_g) = F(P_g) + \gamma E(P_g) + \lambda_p (P_g - P_G^{\lim})^2$	$FE_{loss}(P_g)$ je zbirna funkcija koja uzima u obzir gubitke snage.
f6	$F_{VPE}(P_g) = F(P_g) + \sum_{g \in G} \left d_g \sin(e_g (P_g^{\min} - P_g)) \right + \lambda_p (P_g - P_G^{\lim})^2$	$F_{VPE}(P_g)$ je funkcija troškova goriva koja uzima u obzir gubitke snage i uticaj otvaranja ventila u termoelektranama; d_g i e_g su koeficijenti udara usled pokretanja ventila u termoelektrani.
f7	$E_{loss}(P_g) = E(P_g) + \lambda_p (P_g - P_G^{\lim})^2$	$E_{loss}(P_g)$ je funkcija emisije gasova koja uzima u obzir gubitke snage u sistemu.
f8	$FE_{VPE}(P_g) = F(P_g) + \sum_{g \in G} \left d_g \sin(e_g (P_g^{\min} - P_g)) \right + \gamma E(P_g) + \lambda_p (P_g - P_G^{\lim})^2$	$FE_{VPE}(P_g)$ je zbirna funkcija koja uzima u obzir gubitke snage i uticaj otvaranja ventila u termoelektrani.

Tabela 9.2. Najbolje i srednje vrednosti, standardne devijacije i srednje procentualne greške rezultata, dobijene primenom AWDO, MSA, PSOUSA i FA za test sistem (Slučaj I).

Funkcija	Vrednost	AWDO	MSA	PSOGSA	FA
f1	Najbolja vrednost	600,111408	600,111408	600,111408	600,111408
	Srednja vrednosti	600,159978	600,111417	600,111408	600,115307
	Stand.devijacija	0,075212	1,23379E-05	4,58952E-08	0,021351
	Srednja pr. greška	8,093470E-03	1,53714E-06	1,73065E-08	0,000650
f2	Najbolja vrednost	0,194203	0,194203	0,194203	0,194203
	Srednja vrednosti	0,194221	0,194203	0,194203	0,194203
	Stand.devijacija	2,54834E-05	2,87182E-09	4,54627E-11	5,57591E-09
	Srednja pr. greška	0,009547	1,48716E-06	4,61545E-08	5,51485E-07
f3	Najbolja vrednost	405,043458	405,043458	405,043458	405,043458
	Srednja vrednosti	405,066663	405,043462	405,043458	405,043458
	Stand.devijacija	0,038901	3,7282E-06	5,60405E-08	9,60373E-08
	Srednja pr. greška	0,005729	9,47535E-07	2,33044E-08	1,92368E-08
f4	Najbolja vrednost	605,998369	605,998370	605,998369	605,998369
	Srednja vrednosti	606,023600	605,998381	618.405798	605,998401
	Stand.devijacija	0,033900	1,5047E-05	10.413550	0,000171
	Srednja pr. greška	0,004163	1,87235E-06	2.047436	5,20071E-06
f5	Najbolja vrednost	407,911455	407,911455	407,911455	407,911455
	Srednja vrednosti	407,924636	407,911458	420.768338	407,911455
	Stand.devijacija	0,025912	2,60421E-06	9.153432	9,13352E-08
	Srednja pr. greška	0,003231	7,97712E-07	3.151881	2,15069E-08
f6	Najbolja vrednost	635,819624	635,875068	635.820110	635,869070
	Srednja vrednosti	638,565176	644,427547	661.440545	640,975784
	Stand.devijacija	5,366131	9,453049	15.576525	7,319519
	Srednja pr. greška	0,431736	1,353753	4.029510	0,810870
f7	Najbolja vrednost	194,178511	194,178511	194.178511	194,178511
	Srednja vrednosti	194,188534	194,178514	204.603907	194,178511
	Stand.devijacija	0,020154	2,17712E-06	6.413748	6,2201E-08


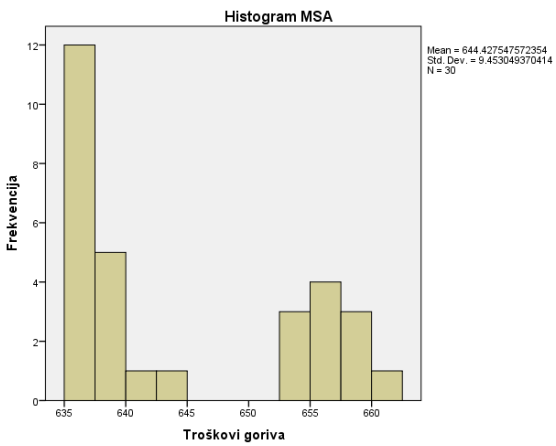

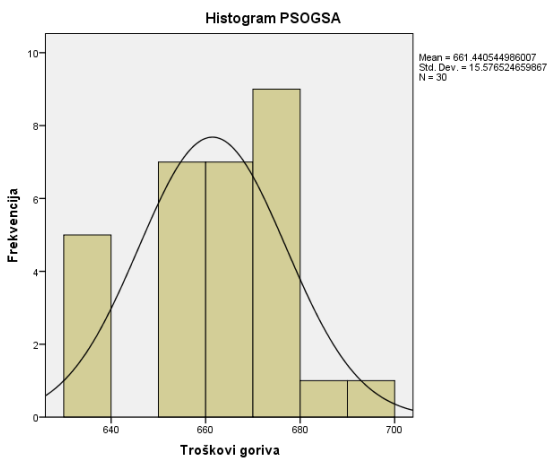

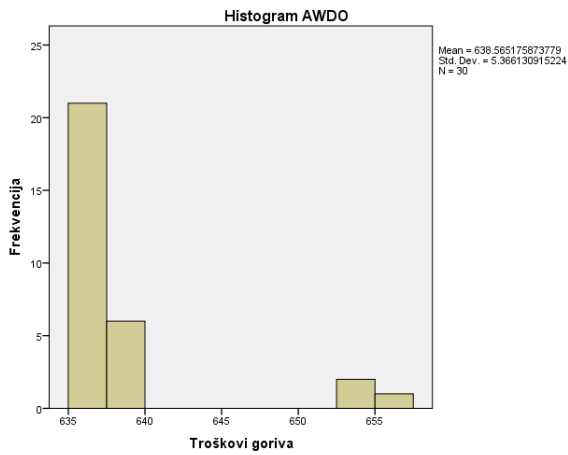
	Srednja pr. greška	0,005162	1,36402E-06	5.368975	3,41853E-08
f8	Najbolja vrednost	430,852030	430,875609	430.852090	430,854329
	Srednja vrednosti	430,959821	431,294850	442.638341	431,226613
	Stand.devijacija	0,117999	0,363465	7.845553	0,748728
	Srednja pr. greška	0,025004	0,102764	2.735568	0,086926

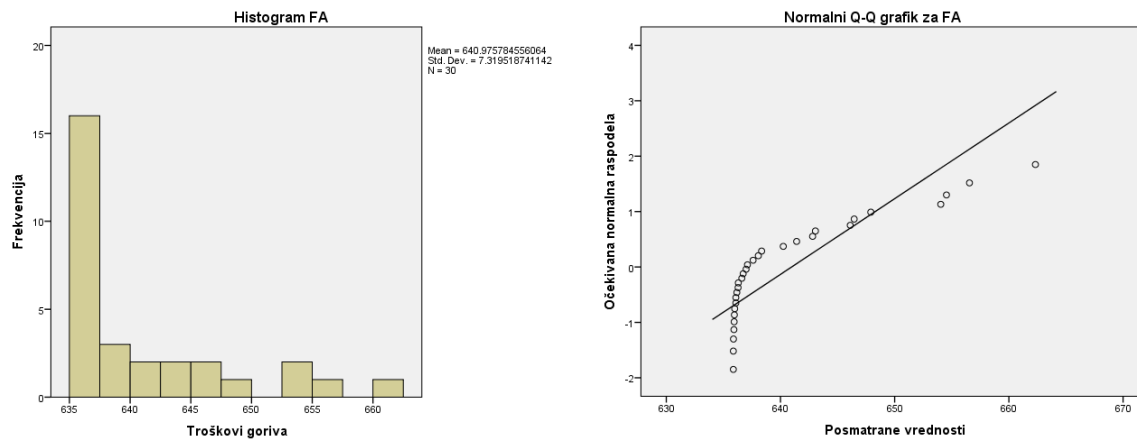
između rangova srednjih vrednosti rezultata koji pripadaju uzorcima dva algoritma. U Tabeli 9.4 su date p -vrednosti dobijene pomoću neparametarskog *Wilcoxon* testa i parametarskog uparenog t -testa (koji je ovde primenjen zbog poređenja rezultata). Parametarski upareni t -test utvrđuje da li je razlika između srednjih vrednosti dva uzorka jednaka nuli. Takođe, u Tabeli 9.4 su date razlike između srednjih procentualnih grešaka dobijenih za sve parove algoritama. Iz Tabele 9.4 se vidi da su p -vrednosti dobijene za parove algoritama pomoću *Wilcoxon* i uparenog t -testa slične. Samo u dva slučaja (kod funkcije f3) p -vrednosti se značajno razlikuju. U ova dva slučaja, *Wilcoxon* neparametarski test je uzet kao merodavan jer je već ranije utvrđeno da za rezultate funkcije f3 nisu ispunjeni uslovi normalnosti (Tabela 9.3). U 22 slučaja p -vrednosti dobijene pomoću *Wilcoxon* testa su manje od nivoa značajnosti od 0,05. To znači da postoji razlika između performansi algoritama koji se upoređuju po parovima i da algoritam koji ima manju vrednost srednje procentualne greške od algoritma sa kojim se upoređuje, ima bolje performanse. Takođe, ako je razlika vrednosti srednjih procentualnih grešaka pozitivna, drugi algoritam u paru je sa boljim performansama, i obrnuto, ako je ta razlika negativna, prvi algoritam u paru je bolji. U dva slučaja p -vrednosti su veće od nivoa značajnosti, što znači da nema razlike u ponašanju između algoritama u ovim parovima. Konačno, iz Tabele 9.4 sledi da p -vrednosti, srednje vrednosti procentualne greške i poređenje algoritama po parovima pokazuju da je PSO GSA najbolji pri minimizaciji funkcija f1 i f2, AWDO je najbolji pri minimiziranju funkcija f3, f6 i f8, MSA je najbolji za funkciju f4 i FA za funkcije f5 i f7.

Prava vrednost p jednog algoritma pri kombinovanju njegovih parnih poređenja sa ostalim algoritmima [11], [75] izračunava se na sledeći način:

Tabela 9.3. *p*-vrednosti testova normalnosti: *Kolmogorov-Smirnov*, *Shapiro-Wilk* i *D'Agostino-Pearson*.

Algoritam	<i>Kolmogorov-Smirnov</i>								<i>Shapiro-Wilk</i>								<i>D'Agostino-Pearson</i>							
	f1	f2	f3	f4	f5	f6	f7	f8	f1	f2	f3	f4	f5	f6	f7	f8	f1	f2	f3	f4	f5	f6	f7	f8
PSO-GSA	0,20	0,076	0,200	0,012	0,200	0,200	0,200	0,185	-	-	-	0,00	0,216	0,112	0,252	0,059	-	0,00	-	0,343	0,636	0,506	0,504	0,708
AWDO	0,00	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,00	0,00	0,00	0,00	0,000	0,000	0,000	0,000	0,00	0,00	0,00	0,003	0,000	0,000	0,000	0,000
MSA	0,00	0,001	0,004	0,000	0,001	0,000	0,001	0,092	0,00	0,00	0,00	0,00	0,001	0,000	0,000	0,006	0,00	0,01	-	0,000	0,000	0,100	0,000	0,006
FA	0,00	0,000	0,000	0,000	0,001	0,000	0,000	0,000	0,00	0,00	0,00	0,00	0,000	0,000	0,000	0,000	0,00	0,00	-	0,000	0,000	0,001	0,000	0,000





Slika 9.1. Histogrami i Q-Q grafici algoritama i AWDO, PSO GSA, MSA i FA primenjenih na f7.

Tabela 9.4. *p*-vrednosti uparenog *t*-testa i *Wilcoxon* testa i razlike srednjih procentualnih grešaka za analizu pojedinačnih funkcija.

Funkcija	Algoritamski par	<i>t</i> -test	<i>Wilcoxon</i> test	Razlike procent. grešaka
f1	PSOGSA-AWDO	0,001	0,000261	-8,093453E-03
	PSOGSA-MSA	0,000	0,000002	-1,519830E-06
	PSOGSA-FA	0,326	0,370935	-6,496159E-04
	AWDO-MSA	0,001	0,000616	8,091933E-03
	AWDO-FA	0,004	0,001833	7,443837E-03
	MSA-FA	0,327	0,000031	-6,480961E-04
f2	PSOGSA-AWDO	0,000	0,020671	-9,547275E-03
	PSOGSA-MSA	-	0,000002	-1,441001E-06
	PSOGSA-FA	-	0,009271	-5,053305E-07
	AWDO-MSA	0,000	0,020671	9,545834E-03
	AWDO-FA	0,000	0,020671	9,546769E-03
	MSA-FA	-	0,000031	9,356707E-07
f3	PSOGSA-AWDO	0,003	0,370935	-5,728980E-03
	PSOGSA-MSA	0,000	0,000002	-9,242305E-07

	PSOGSA-FA	0,419	0,040702	4,067671E-09
	AWDO-MSA	0,003	0,382034	5,728056E-03
	AWDO-FA	0,003	0,370935	5,728984E-03
	MSA-FA	0,000	0,000002	9,282981E-07
f4	PSOGSA-AWDO	0,000	0,001569	2,043272E+00
	PSOGSA-MSA	0,000	0,008730	2,047434E+00
	PSOGSA-FA	0,000	0,008730	2,047431E+00
	AWDO-MSA	0,000	0,102011	4,161648E-03
	AWDO-FA	0,000	0,102011	4,158320E-03
	MSA-FA	0,525	0,000031	-3,328359E-06
f5	PSOGSA-AWDO	0,000	0,000008	3,148649E+00
	PSOGSA-MSA	0,000	0,000008	3,151880E+00
	PSOGSA-FA	0,000	0,000008	3,151881E+00
	AWDO-MSA	0,009	0,673280	3,230555E-03
	AWDO-FA	0,009	0,658331	3,231331E-03
	MSA-FA	0,000	0,000002	7,762047E-07
f6	PSOGSA-AWDO	0,000	0,000026	3,597774E+00
	PSOGSA-MSA	0,000	0,000332	2,675756E+00
	PSOGSA-FA	0,000	0,000041	3,218640E+00
	AWDO-MSA	0,007	0,005320	-9,220173E-01
	AWDO-FA	0,186	0,328571	-3,791337E-01
	MSA-FA	0,110	0,059836	5,428836E-01
f7	PSOGSA-AWDO	0,000	0,000003	5,363813E+00
	PSOGSA-MSA	0,000	0,000003	5,368974E+00
	PSOGSA-FA	0,000	0,000003	5,368975E+00
	AWDO-MSA	0,011	0,093676	5,160390E-03
	AWDO-FA	0,011	0,035009	5,161720E-03
	MSA-FA	0,000	0,000002	1,329837E-06
f8	PSOGSA-AWDO	0,000	0,000012	2,710564E+00
	PSOGSA-MSA	0,000	0,000014	2,632804E+00
	PSOGSA-FA	0,000	0,000010	2,648642E+00

	AWDO-MSA	0,000	0,000010	-7,775964E-02
	AWDO-FA	0,046	0,036826	-6,192187E-02
	MSA-FA	0,669	0,054463	1,583777E-02

$$p = 1 - \prod_{i=1}^k (1 - p_i) \quad (9.1)$$

gde je p_i vrednost verovatnoće poređenja u i -tom paru a k je broj poređenja jednog algoritma. U Tabeli 9.5 date su izračunate prave vrednosti p za svaki algoritam pri čemu su uzimani parovi u kojima taj algoritam ima bolje performance. Ako se vrednosti p dobijene iz (9.1) uzmu kao nivoi značajnosti α , iz njih se izračunavaju vrednosti odgovarajućih intervala pouzdanosti kao: $100(1 - \alpha)$. U Tabeli 9.5 su date i ove vrednosti. Iz Tabele 9.5 i Tabele 9.1 može se zaključiti:

- PSOGSA ima prednost nad drugim algoritmima pri rešavanju ERS problema ako se u funkcijama cilja ne uzimaju u obzir efekat otvaranja ventila i gubici u sistemu.
- FA i MSA ima prednosti pri rešavanju ERS problema ako funkcija cilja uzima u obzir gubitke u sistemu.
- AWDO je bolji od ostalih algoritama u slučaju kada su funkcije cilja najsloženije, tj., kada one uzimaju u obzir efekat otvaranja ventila i gubitke u sistemu.

Tabela 9.5. Prave vrednosti p i intervali pouzdanosti za algoritme sa boljim performansama u paru.

Funkcija	Algoritam sa boljim Performansama	Prave vrednost p	Interval pouzdanosti, %
f1	PSOGSA	0,000263	99,97
f2	PSOGSA	0,029752	97,02
f3	AWDO	0,040704	95,93

f4	MSA	0,008761	99,12
f5	FA	0,000010	100,00
f6	AWDO	0,005346	99,46
f7	FA	0,035014	96,50
f8	AWDO	0,036847	96,31

9.2 Primena statističkih testova za grupu funkcija

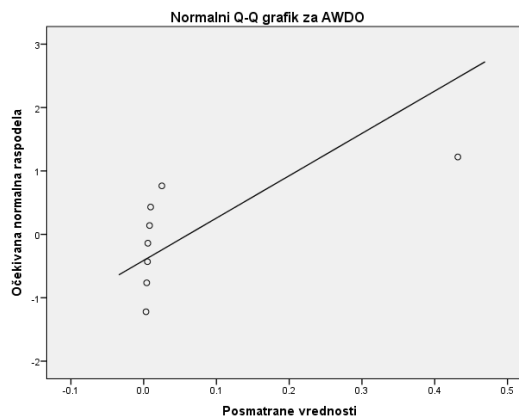
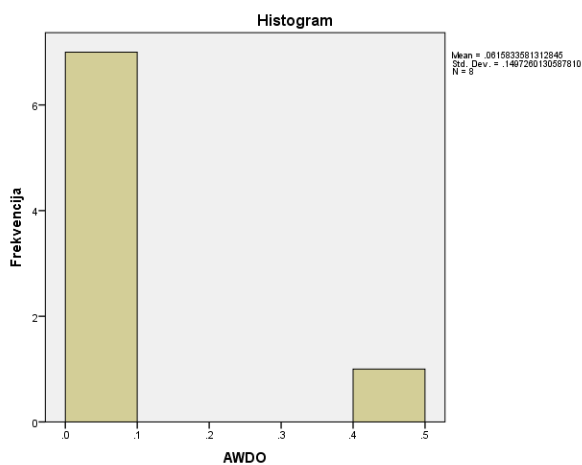
Da bi se izvršila analiza ponašanja algoritama pri rešavanju cele grupe funkcija, vrše se upoređivanja dva ili više algoritama primenom parametarskih i neparametarskih testova na rezultate svih funkcija istovremeno. Najpre se dobijaju srednje vrednosti rezultata svake pojedinačne funkcije posle 30 puštanja svakog algoritma. Te srednje vrednosti se, u ovom radu, dobijaju kao srednje vrednosti procentualnih grešaka u odnosu na najbolju vrednost i nazivaju se srednje procentualne greške (Tabela 9.2). Na dobijenom uzorku, koji se sastoji od srednjih procentualnih grešaka, primenjuje se test normalnosti da bi se utvrdilo da li sa sigurnošću mogu da se primene parametarski testovi. Rezultati primene testa normalnosti dati su u Tabeli 9.6 i ilustrovani na Slici 9.2. Iz Tabele 9.6 se vidi da je uslov normalnosti ispunjen u slučaju primene PSOGSA a da za AWDO, MSA i FA taj uslov nije ispunjen. Histogrami i Q-Q grafici koji su prikazani na Slici 9.2 potvrđuju rezultate prikazane u Tabeli 9.6. Rezultat Levenovog testa je $p = 0,00$ (p -vrednost je manja od usvojenog nivoa značajnosti od 0,05) što pokazuje da uzoračke varijanse algoritama nisu homogene. Na osnovu toga, zaključuje se da postoji razlika između varijansi raspodela sva četiri algoritma primenjena na uzorku sačinjenom od rezultata svih osam razmatranih funkcija. Pošto uslovi normalnosti i homogenosti nisu verifikovani, zaključuje se da parametarski testovi nisu pogodni za dalju analizu problema primene algoritama na grupi od osam funkcija. Zbog toga se u nastavku primenjuju neparametarski testovi za analizu rezultata grupe funkcija.

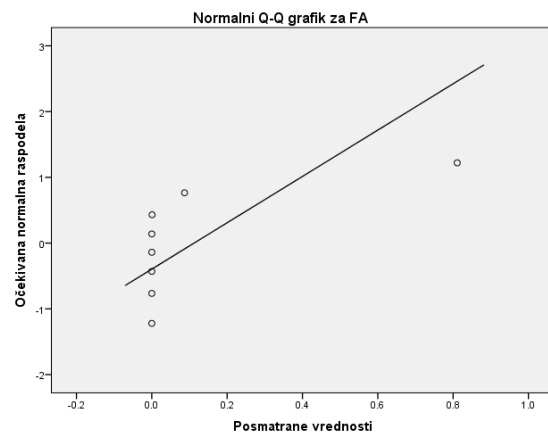

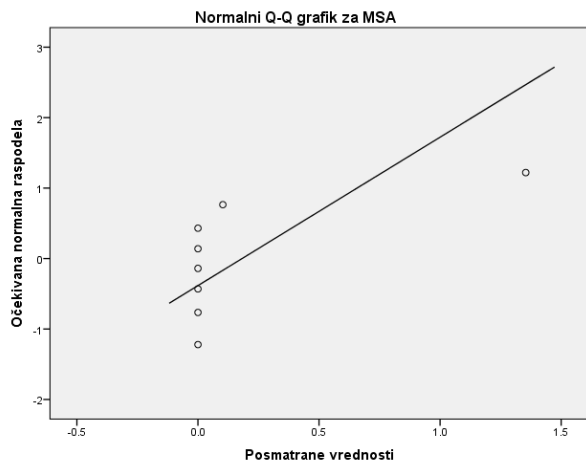
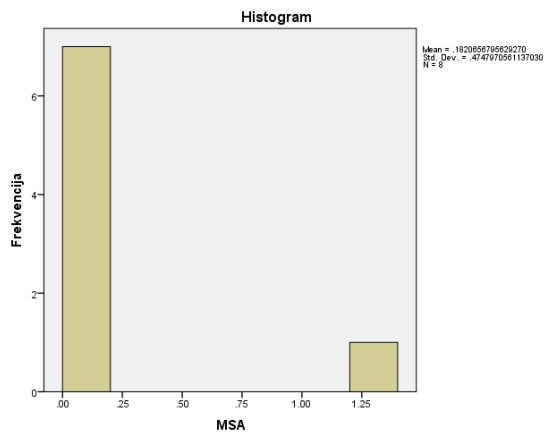
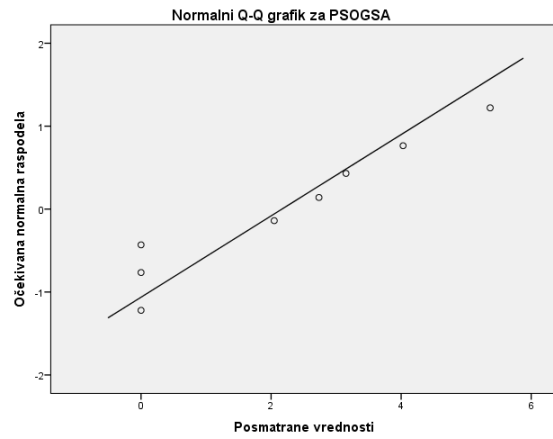
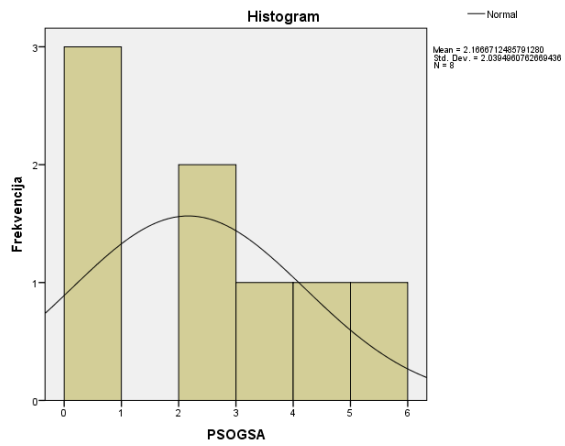
Wilcoxon i *Friedman* testovi su neparametarski statistički testovi koji se, u ovom radu, pri analizi rezultata grupe funkcija, primenjuju za upoređivanje algoritama u parovima. Oba testa utvrđuju da li dve grupe rezultata dobijene primenom dva algoritma

Tabela 9.6. p -vrednosti testova normalnosti za analizu problema sa grupom funkcija.

Algoritam	<i>Kolmogorov-Smirnov</i>	<i>Shapiro-Wilk</i>	<i>D'Agostino-Pearson</i>
PSOGSA	0,133	0,079	0,4306
AWDO	0,000	0,000	0,000
MSA	0,000	0,000	0,000
FA	0,000	0,000	0,000

predstavljaju dve populacije sa različitim vrednostima mediane. U Tabeli 9.7 su prikazani rezultati dobijeni *Wilcoxon*-ovim i *Friedman*-ovim testovima, tj., p -vrednosti za svaki par algoritama koji su primenjeni na grupi od svih osam funkcija. Iz Tabele 9.7 se vidi da sve p -vrednosti iznose $p > 0,05$ što znači da se upoređivani algoritmi statistički ponašaju na isti način, tj., algoritmi imaju iste performanse a razlike između grupa rezultata, dobijene za svaki par algoritama, nisu statistički značajne.





Slika 9.2. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na celoj grupi funkcija.

Tabela 9.7. *p*-vrednosti testova *Wilcoxon* i *Friedman* za analizu problema sa grupom funkcija.

Algoritamski par	<i>Wilcoxon</i> test	<i>Friedman</i> test
PSOGSA-AWDO	0,093	0,480
MSA-AWDO	0,674	0,157
FA-AWDO	0,674	0,157
MSA-PSOGSA	0,093	0,480
FA-PSOGSA	0,093	0,157
FA-MSA	0,889	0,157

9.3 Zaključak

Pri rešavanju nekog složenog optimizacionog problema primenom MA, često je potrebno primeniti jedan MA na više funkcija pojedinačno ili zajedno. Jedan takav problem, za čije rešavanje je predložen veliki broj MA, je ERS problem. U ovoj glavi je izvršena statistička analiza ponašanja četiri MA pri rešavanju osam funkcija koje opisuju ERS problem. Pri tome, primenjeni su parametarski i neparametarski statistički testovi. Izvršene su dve vrste analize:

1. analiza rezultata dobijenih za svaku funkciju pojedinačno
2. analiza rezultata dobijenih za sve funkcije istovremeno

Testovi normalnosti (*Kolmogorov-Smirnov*, *Shapiro-Wilk* i *D'Agostino-Pearson*) pokazuju da su uslovi normalnosti ispunjeni u slučaju primene algoritma PSOGSA (na pojedinačnim funkcijama i na svim funkcijama istovremeno) a da ovi uslovi nisu ispunjeni u slučajevima primene ostala tri algoritma (FA, MSA i AWDO). Rezultati *Levene* testa su pokazali da uslovi homogenosti nisu potvrđeni niti za rezultate pojedinačnih funkcija niti za rezultate svih funkcija istovremeno. Pošto uslovi normalnosti i homogenosti nisu zadovoljeni, zaključeno je da parametarski testovi nisu prihvatljivi za dalju analizu. Nakon toga, primenjeni su neparametarski *Wilcoxon* test i parametarski upareni *t*-test na rezultate pojedinačnih funkcija i oni su pokazali da su u ovom slučaju rezultati dobijeni parametarskim i neparametarskim testovima slični. Iz

ovih rezultata sledi da PSOGSA daje najbolje rezultate pri minimizaciji funkcija f_1 i f_2 , AWDO je najbolji za funkcije f_3 , f_6 i f_8 a MSA za funkciju f_4 dok je FA pokazao najbolje rezultate pri primeni na funkcijama f_5 i f_7 . To znači da jedan MA ne može dati najbolje rezultate za svaku funkcije ERS problema. Zbog toga je pri rešavanju ERS problema bolje primeniti veći broj MA nego jedan MA. Analiza rezultata dobijenih za sve funkcije zajedno primenom neparametarskog *Wilcoxon* testa je pokazala da se sva četiri MA statistički ponašaju na isti način tj., razlike između grupa rezultata dobijenih za svaki par algoritama nisu statistički značajne.

Postupak koji je predložen u ovoj glavi može se primeniti za rešavanje drugih složenih višestrukih problema u cilju izbora najboljeg optimizacionog algoritma.

10. ZAKLJUČAK

Stalni zahtevi za rešavanjem sve složenijih optimizacionih problema u nauci, tehnici, ekonomiji, industriji i drugim oblastima ljudske delatnosti su doveli do razvoja velikog broja MA među kojima se najveći broj bazira na ponašanju populacija u prirodi. Da bi se postigla što veća tačnost pri rešavanju optimizacionih problema primenom MA, vrši se njihovo usavršavanje hibridizacijom i uvođenjem novih operatora. Međutim, u skladu sa teoremom „*No free lunch*“, nije moguće pronaći jedan MA koji će biti najbolji za sve probleme a da bi se dizajnirao MA za odgovarajući problem, potrebno je poznavati taj problem. U ovoj disertaciji predloženi su algoritmi MSA i AWDO, kao dva nova populaciona MA, za rešavanje kompleksnog ERS problema u elektroenergetici, koji je opisan složenim nelinearnim funkcijama. Algoritmi MSA i AWDO su odabrani zbog poboljšanih performansi u odnosu na druge populacione MA. MSA ima dva optimizaciona operatora: Vektor *Levy*-mutacije za poboljšanje procesa diverzifikacije i ALIM za poboljšanje pretraživanja u uskim domenima. AWDO je hibridni algoritam koji se sastoji od dva algoritma: WDO i CMAES. Dobre performanse AWDO su omogućene time što WDO vrši uspešno pretraživanje rešenja a brzi algoritam CMAES vrši optimizaciju parametara algoritma u svakoj iteraciji.

Problem ERS je odabran kao ključni problem u planiranju i radu elektroenergetskog sistema u kojem se minimizira funkcija troškova goriva i/ili funkcija količine emitovanih toksičnih gasova (SO_x , CO_2 i NO_x).

Predloženi MA za rešavanje ERS problema su testirani i upoređivani sa drugim algoritmima, pri čemu su korišćeni standardni elektroenergetski test sistemi sa različitim brojevima generatora. Najpre je algoritam MSA uspešno testiran na dva standardna IEEE test sistema sa 3 i 6 generatora, bez uzimanja u obzir efekta otvaranja ventila u termoelektranama. Radi poređenja rezultata istovremeno sa MSA testirani su algoritmi PSOGSA i FA. Komparativna analiza rezultata je pokazala da je standardna devijacija rezultata najmanja u slučaju primene MSA. Minimalne vrednosti troškova goriva i emisije NO_x gasova, dobijene primenom MSA su jednake odgovarajućim vrednostima dobijenim primenom FA i PSOGSA ali su bolje nego odgovarajuće vrednosti dobijene u publikovanoj literaturi primenom drugih MA na istim test sistemima. Profili konvergenције su pokazali da MSA ima najbolje konvergentne osobine u odnosu na

PSOGSA i FA. Poređenjem profila konvergencije, standardnih devijacija i optimalnih vrednosti rezultata dobijenih u ovoj disertaciji i u publikovanoj literaturi pokazano je da MSA ima najbolju efektivnost i robusnost pri rešavanju ERS problema na primenjenim test sistemima.

Nakon prethodnog testiranja sprovedeno je novo testiranje predloženih algoritama MSA i AWDO na IEEE test sistemu sa 6 generatora, u kome se uzima u obzir uticaj otvaranja ventila u termoelektranama na snage generatora, čime funkcije cilja postaju složenije nego u prethodnom testu. Pri ovim testiranjima, višeciljni ERS problem je pretvoren u problem sa jednom funkcijom cilja primenom težinskog faktora. Na ovom test primeru, pored AWDO i MSA, testirani su, radi poređenja rezultata, i algoritmi PSOGSA i FA. Ova dva algoritma su odabrana zbog toga što su pokazala bolje performanse u odnosu na ranije predložene MA u literaturi za rešavanje ERS problema. Testiranje je vršeno za različite varijante ERS problema: (i) optimizacija troškova goriva; (ii) optimizacija emisije zagađujućih gasova; (iii) optimizacija troškova goriva i emisije gasova, istovremeno; (iv) optimizacija sa jednostavnijim funkcijama cilja tj., bez uticaja otvaranja ventila u termoelektranama; (v) optimizacija sa složenijim funkcijama cilja tj., sa uticajem otvaranja ventila. Pored toga, u svim ovim slučajevima uzimani su u obzir gubici snage u sistemu. Rezultati simulacije su pokazali da AWDO daje najbolje rezultate za minimalne troškove goriva i iste vrednosti minimalne emisije gasova u odnosu na ostala tri primenjena algoritma. Zbog toga, AWDO daje i najbolje ekonomske efekte. Standardna devijacija rezultata dobijenih primenom AWDO je najmanja u odnosu na preostala tri algoritma a konvergencija rezultata je najbrža. Na osnovu svih rezultata dobijenih u ovom testu, algoritam AWDO je pokazao da ima najbolje osobine robusnosti, efektivnosti i efikasnosti u odnosu na preostala tri algoritma što ga čini boljim algoritmom od svih do sada predloženih MA za rešavanje ERS problema sa složenim funkcijama koje sadrže nelinearnosti izazvane efektom ventila u termoelektranama i uvrštavanjem dodatnih izraza za minimizaciju gubitaka snage u sistemu.

Nakon testiranja algoritama, AWDO je primenjen na objedinjenom modelu ERS i lanca snabdevanja električnom energijom. Objedinjeni model je izveden u ovom radu i predložen zajedno sa odgovarajućom procedurom za proračun tokova snaga na tržištu električne energije i cena električne energije minimizacijom troškova goriva i emisije

štetnih gasova i maksimizacijom profita učesnika u lancu snabdevanja. Ova procedura se može primeniti pri upravljanju tržištem električne energije i višekriterijumskom donošenju odluka od strane učesnika u lancu snabdevanja.

Na rezultate dobijene predloženim algoritmima MSA i AWDO primenjeni su statistički parametarski i neparametarski testovi kako bi se utvrdila razlika u ponašanju algoritama pri dobijanju rezultata na pojedinačnim funkcijama ERS problema i na svim funkcijama istovremeno i kako bi se utvrdilo da li se mogu generalizovati zaključci iz konkretnih skupova rešenja na celu populaciju mogućih rešenja. Rezultati statističke analize su pokazali da se algoritmi ponašaju različito za različite funkcije ERS problema tj., da jedan algoritam ne može biti najbolji za svaku funkciju problema. To znači da je u slučajevima rešavanja problema sa većim brojem funkcija bolje primeniti veći broj algoritama umesto jednog. Postupak koji je u disertaciji primenjen za analizu ponašanja algoritama može se primeniti za rešavanje drugih kompleksnih višestrukih problema u cilju izbora najboljeg optimizacionog algoritma.

Na osnovu sprovedenih istraživanja u ovoj disertaciji, mogu se izdvojiti sledeći njeni glavni doprinosi:

1. Po prvi put je izvršeno testiranje novih unapređenih hibridnih algoritama: MSA i AWDO za rešavanje kompleksnog ERS problema i pokazano je da oni daju kvalitetna rešenja koja su bolja u odnosu na rešenja dobijena primenom drugih ranije predloženih MA;
2. Predloženi algoritam AWDO je uspešno primenjen na novom, u disertaciji razvijenom, proširenom modelu ERS koji obuhvata uticaj ERS na lanac snabdevanja na deregulisanom tržištu električne energije i
3. Razvijen je i uspešno primenjen postupak analize statističkog ponašanja većeg broja MA u rešavanju kompleksnih problema sa većim brojem funkcija cilja, pri čemu se analiza vrši primenom parametarskih i neparametarskih testova na rezultate dobijene za pojedinačne funkcije i za sve funkcije istovremeno.

Praktičan doprinos disertacije ogleda se u mogućnosti primene MSA i AWDO za poboljšanja tačnosti i brzine upravljanja potrošnjom goriva i emisijom gasova u termoelektranama na bazi ulazno-izlaznih karakteristika generatora, i u mogućnosti poboljšanja koordinacije u upravljanju elektranom i tržištem električne energije

korišćenjem jednog ili većeg broja efikasnih MA odabranih statističkom analizom ponašanja algoritama.

11. LITERATURA

- [1] X. S. Yang, Nature-Inspired Optimization Algorithms, e-Book , Elsevier, 2014.
- [2] E. G. Talbi, Metaheuristics from design to implementation, A John Wiley & Sons, Inc., Hoboken, New Jersey, 2009.
- [3] K. Sörensen, Metaheuristics - the metaphor exposed, *International Transactions in Operational Research*, vol. 22, pp. 3-18, 2015.
- [4] J. Radosavljević, Metaheuristic Optimization in Power Engineering, *The Institution of Engineering and Technology*, London, United Kingdom, 2018.
- [5] A. A. Mohamed, Y. S. Mohamed, A. A. M. El-Gaafary, and A. M. Hemeida, Optimal power flow using moth swarm algorithm, *Electric Power Systems Research*, vol. 142, pp. 190-206, 2017.
- [6] Z. Bayraktar, and M. Komurcu, Adaptive wind driven optimization, *Proceedings of 9th EAI International Conference on Bio-inspired Information and Communications Technologies (BIONETICS)*, New York, pp. 124-127, 2016.
- [7] Z. Bayraktar, M. Komurcu, and D. H. Werner, Wind Driven Optimization (WDO): a novel nature-inspired optimization algorithm and its application to electromagnetics, *Proceedings of 2010 IEEE Antennas and Propagation Society International Symposium (APSURSI)*, pp. 1-4, Toronto, Canada, 2010.
- [8] N. Hansen, and A. Ostermeier, Completely derandomized self-adaptation in evolutionary strategies, *Evolutionary Computation*, vol. 9, no. 2, pp. 159–195, 2001.
- [9] M. D. Gregory, Z. Bayraktar, and D. H. Werner, Fast optimization of electromagnetic design problems using the covariance matrix adaptation evolutionary strategy, *IEEE Transactions on Antennas and Propagation*, vol. 59, no. 4, pp. 1275-1285, 2011.
- [10] S. Garcia, D. Molina, M. Lozano, and F. Herrera, A study on the use of non-parametric tests for analyzing the evolutionary algorithms' behaviour a case study on the CEC'2005 Special Session on Real Parameter Optimization, *Journal of Heuristics*, vol. 15, pp. 617-644, 2009.

- [11] S. Garcia, A. Fernandez, J. Luengo, and F. Herrera, Advanced nonparametric tests for multiple comparisons in the design of experiments in computational intelligence and data mining: Experimental analysis of power, *Information Sciences* vol. 180, no. 10, pp. 2044-2064, 2010.
- [12] J. Demšar, Statistical comparisons of classifiers over multiple data sets, *Journal of Machine Learning Research*, vol. 7, pp. 1-30, 2006.
- [13] H. R. Sedeghian, and M. M. Ardehali, A novel approach for optimal economic dispatch scheduling of integrated combined heat and power systems for maximum economic profit and minimum environmental emissions based on Benders decomposition, *Energy*, vol. 102, pp. 10-23, 2016.
- [14] S. Yang, J. Yao, and T. Kang, An efficiency oriented model of electricity market in transition period, *International Journal of Electrical Power & Energy Systems*, vol. 54, pp. 221–225, 2014.
- [15] Y. Dai, H. Yang, and J. Wu, Electricity supply chain coordination based on quantity discount contracts, *Proceedings of 2009 IEEE International Conference on Industrial Technology ICIT 2009*, 10-13 Feb. 2009, Gippsland, Australia, 1-5.
- [16] Z. Liu, and A. Nagurney, An Integrated Electric Power Supply Chain and Fuel Market Network Framework: Theoretical Modeling with Empirical Analysis for New England, *Naval Research Logistics*, vol. 56, no. 7, pp. 600-624, 2009.
- [17] D. H. Wolpert, W. G. Macready, No free lunch theorems for optimization, *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, pp. 67-82, 1997.
- [18] R. Ferrero, J. F. Rivera, and S. M. Shahidehpour, Application of games with incomplete information for pricing electricity in deregulated power pools, *IEEE Transactions on Power Systems*, vol. 13, no. 1, pp. 184-189, 1998.
- [19] M. H. R. Nascimento, M. V. A. Nunes, J. L. M. Rodríguez, and J. C. Leite, A new solution to the economical load dispatch of power plants and optimization using differential evolution, *Electrical Engineering*, vol. 99, no. 2, pp. 561-571, 2017.
- [20] R. Storn, and K. Price, Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces, *Journal of Global Optimization*, vol. 11, no. 4, pp. 341–359, 1997.

- [21] A. A. Abou El Ela, M. A. Abido, and S. R. Spea, Differential evolution algorithm for emission constrained economic power dispatch problem, *Electric Power Systems Research*, vol. 80, no. 10, pp. 1286-1292, 2010.
- [22] B. Y. Qu, J. J. Liang, Y. S. Zhu, and P. N. Suganthanl, Solving dynamic economic emission dispatch problem considering wind power by multi-objective differential evolution with ensemble of selection method, *Natural Computing*, pp. 1-9, 2017.
- [23] A. Bhattacharya, and P. K. Chattopadhyay, Solving economic emission load dispatch problems using hybrid differential evolution, *Applied Soft Computing*, vol. 11, no. 2, pp. 2526–2537, 2011.
- [24] P. K. Roy, S. P. Ghoshal, and S. S. Thakur, Combined economic and emission dispatch problems using biogeography-based optimization, *Electrical Engineering*, vol. 92, no. 4, pp. 173–184, 2010.
- [25] J. Singh, and S. K. Goyal, Transmission constrained economic load dispatch using biogeography based optimization, Proceedings of 2014 IEEE International Conference on Computational Intelligence and Computing Research (ICCIIC), pp. 1-5, Coimbatore, India, December 18-20, 2014.
- [26] T. Niknam, H. D. Mojarrad, and B. B. Firouzi, A new optimization algorithm for multi-objective economic/emission dispatch, *International Journal of Electrical Power and Energy Systems*, vol. 46, pp. 283–293, 2013.
- [27] M. Mitchell, An Introduction to Genetic Algorithms, MIT Press Cambridge, MA, USA, 1998, ISBN:0262631857.
- [28] R. T. F. A. King, and H. C. S. Rughooputh, Elitist multiobjective evolutionary algorithm for environmental/economic dispatch, *Evolutionary Computation, 2003. CEC '03. The 2003 Congress on*, vol. 2, pp. 1108-1114, Canberra, Australia, December 8–12, 2003.
- [29] M. A. Abido, Multiobjective evolutionary algorithms for electric power dispatch problem, *IEEE Transactions on Evolutionary Computation*, vol. 10, no. 3, pp. 315 – 329, 2006.
- [30] N. Srinivas and K. Deb, Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms, *Evolutionary Computation*, vol. 2, no. 3, pp. 221 – 248, 1994.

- [31] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, A Fast Elitist Multiobjective Genetic Algorithm: NSGA-II“. *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182 – 197, 2002.
- [32] J. Horn, N. Nafpliotis, and D. E. Goldberg, A Niche Pareto Genetic Algorithm for Multiobjective Optimization, *Proceedings of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence (ICEC '94)*, 27-29 June 1994, vol. 1, pp. 82-87, Orlando, FL, USA.
- [33] J. Kennedy, and R. Eberhart, Particle Swarm Optimization, *Proceedings of IEEE International Conference on Neural Networks*, pp. 1942–1948, 1995.
- [34] D. Karaboga and B. Basturk, A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm, *Journal of Global Optimization*, vol. 39, pp. 459-471, 2007.
- [35] X. S. Yang, Firefly Algorithm, Lévy Flights and Global Optimization, *Research and Development in Intelligent Systems*, vol. 26, pp. 209-218, 2010.
- [36] K.M. Passino, Biomimicry of bacterial foraging for distributed optimization and control, *IEEE Control Systems*, vol. 22, no.3, pp. 52–67, 2002
- [37] M.Y. Cheng, and D. Prayogo, Symbiotic organisms search: a new metaheuristic optimization algorithm, *Computers and Structures*, vol. 139, pp. 98–112, 2014
- [38] A. H. Gandomi, and A. H. Alavi, Krill herd: A new bio-inspired optimization algorithm, *Communications in Nonlinear Science and Numerical Simulation*, vol. 17, no. 12, pp. 4831-4845, 2012.
- [39] S. Mirjalili, S. M. Mirjalili, and A. Lewis, Grey Wolf Optimizer, *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014.
- [40] N. A. Khan, G. A. S. Sidhu, and F. Gao, Optimizing Combined Emission Economic Dispatch for Solar Integrated Power Systems, *IEEE Access*, vol. 4, pp. 3340-3348, 2016.
- [41] H. Hamed, Solving the combined economic load and emission dispatch problems using new heuristic algorithm, *International Journal of Electrical Power & Energy Systems*, vol. 46, pp. 10–16, 2013.

- [42] M. A. Abido, Multiobjective particle swarm optimization for environmental/economic dispatch problem, *Electric Power Systems Research*, vol. 79, no. 7, pp. 1105-1113, 2009.
- [43] T. Niknam, and H. Doagou-Mojarrad, Multiobjective economic/emission dispatch by multiobjective θ -particle swarm optimization, *IET Generation, Transmission & Distribution*, vol. 6, no. 5, pp. 363-370, 2012.
- [44] D. W. Gong, Y. Zhang, and C. L. Qi, Environmental/economic power dispatch using a hybrid multi-objective optimization algorithm, *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 6, pp. 607-614, 2010.
- [45] S. Ozyon, and D. Aydin, Incremental artificial bee colony with local search to economic dispatch problem with ramp rate limits and prohibited operating zones, *Energy Conversion and Management*, vol. 65, pp. 397-407, 2013.
- [46] D. Aydin, S. Ozyon, C. Yasar, and T. Liao, Artificial bee colony algorithm with dynamic population size to combined economic and emission dispatch problem, *International Journal of Electrical Power & Energy Systems*, vol. 54, pp. 144–153, 2014.
- [47] A. G. Abro, and J. M. Saleh. Enhanced probability-selection artificial bee colony algorithm for economic load dispatch: A comprehensive analysis, *Engineering Optimization*, vol. 46, no. 10, pp. 1315-1330, 2014.
- [48] A. Ghasemi, A fuzzified multi objective interactive honey bee mating optimization for environmental/economic power dispatch with valve point effect, *International Journal of Electrical Power & Energy Systems*, vol. 49, 308–321, 2013.
- [49] E. Rashedi, H. Nezamabadi-pour, and S. Saryazdi, GSA: A Gravitational Search Algorithm, *Information Sciences*, Vol. 179, no. 13, pp. 2232-2248, 2009.
- [50] U. Güvenç, Y. Sönmez, S. Duman, and N. Yörükeren, Combined economic and emission dispatch solution using Gravitational search algorithm, *Scientia Iranica*, vol.19, no. 6, pp. 1754–1762, 2012.

- [51] R. J. Chinasamy Hemparuva, S. P. Simon, S. Kinattingal, and S. R. N. Panugothu, Gravitational search algorithm-based dynamic economic dispatch by estimating transmission system losses using A-loss coefficients, *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 24, no. 5, pp. 3769-3781, 2016.
- [52] B. Shaw, V. Mukherjee, and S. P. Ghoshal, A novel opposition-based gravitational search algorithm for combined economic and emission dispatch problems of power systems, *International Journal of Electrical Power & Energy Systems*, vol. 35, no. 1, pp. 21-33, 2012.
- [53] J. Radosavljević, A solution to the combined economic and emission dispatch using hybrid PSO-GSA algorithm, *Applied Artificial Intelligence*, vol. 30, no. 5, pp. 445-474, 2016.
- [54] S. Mirjalili, and S. Z. M. Hashim, A new hybrid PSO-GSA algorithm for function optimization, *2010 International Conference on Computer and Information Application (ICCIA 2010)*, Tianjin, China, December 3–5, 2010.
- [55] S. Jiang, Z. Ji, and Y. Shen, A novel hybrid particle swarm optimization and gravitational search algorithm for solving economic emission load dispatch problems with various practical constraints, *International Journal of Electrical Power & Energy Systems*, vol. 55, pp. 628-644, 2014.
- [56] P. K. Hota, A. K. Barisal, and R. Chakrabarti, Economic emission load dispatch through fuzzy based bacterial foraging algorithm, *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 7, pp. 794-803, 2010.
- [57] V. R. Pandi, B. K. Panigrahi, W. C. Hong, and R. Sharma, A multiobjective bacterial foraging algorithm to solve the environmental economic dispatch problem, *Energy Sources, Part B: Economics, Planning and Policy*, vol. 9, no. 3, pp. 236-247, 2014.
- [58] M. Jevtić, N. Jovanović, J. Radosavljević, D. Klimenta, Moth Swarm Algorithm for Solving Combined Economic and Emission Dispatch Problem, *Elektronika ir Elektrotehnika*, vol. 23, no. 5, pp. 21-28, 2017.
- [59] G. Chen, and X. Ding, Optimal economic dispatch with valve loading effect using self-adaptive firefly algorithm, *Applied Intelligence*, vol. 42, no. 2, pp. 276-288, 2015.

- [60] M. K. Dosoglu, U. Guvenc, S. Duman, Yusuf Sonmez, and H. T. Kahraman, Symbiotic organisms search optimization algorithm for economic/emission dispatch problem in power systems, *Neural Computing and Applications*, vol. 29, no. 3, pp. 721-737, 2018.
- [61] X. Yang, Flower pollination algorithm for global optimization, in *Unconventional Computation and Natural Computation UCNC 2012*, Lecture Notes in Computer Science, vol. 7445, pp. 240–249, Berlin, Heidelberg: Springer, 2012.
- [62] A.Y. Abdelaziz, E.S. Ali, and S.M. AbdElazim, Combined economic and emission dispatch solution using flower pollination algorithm, *International Journal of Electrical Power & Energy Systems*, vol. 80, pp. 264–274, 2016.
- [63] R. N. Mantegna, Fast, accurate algorithm for numerical simulation of Levy stable stochastic processes, *Physical Review E*, vol. 49, no. 5, pp. 4677–4683, 1994.
- [64] B. S. Rao, and K. Vaisakh, Multi-objective adaptive clonal selection algorithm for solving environmental/economic dispatch and OPF problems with load uncertainty, *International Journal of Electrical Power & Energy Systems*, vol. 53, pp. 390–408, 2013.
- [65] L.N. Castro, and F.J. Zuben, Learning and optimization using the Clonal selection principle, *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 3, pp. 239–251, 2002.
- [66] L. Benasla, A. Belmadani, and M. Rahli, Spiral optimization algorithm for solving combined economic and emission dispatch, *International Journal of Electrical Power & Energy Systems*, vol. 62, pp. 163-174, 2014.
- [67] K. Tamura, and K. Yasuda, Spiral dynamics inspired optimization, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, vol. 15, no. 8, pp. 1116–1122, 2011.
- [68] D. H. Zerigat, L. Benasla, and A. Belmadani, Galaxy-based search algorithm to solve combined economic and emission dispatch, *UPB Scientific Bulletin, Series C: Electrical Engineering*, vol. 76, no. 1, pp. 209-220, 2014.

- [69] H. S. Hosseini, Principal components analysis by the galaxy-based search algorithm: a novel metaheuristic for continuous optimization, *International Journal of Computational Science and Engineering*, vol. 6, no. 1/2, pp. 132-140, 2011.
- [70] M. Basu, Quasi-oppositional group search optimization for multi-area dynamic economic dispatch, *International Journal of Electrical Power & Energy Systems*, vol. 78, pp. 356–367, 2016.
- [71] S. He, Q. H. Wu, and J. R. Saunders, Group search optimizer: an optimization algorithm inspired by animal searching behavior, *IEEE Transactions on Evolutionary Computation*, vol. 13, no. 5, pp. 973–990, 2009.
- [72] V. K. Kamboj, S. K. Bath, and J. S. Dhillon, Solution of non-convex economic load dispatch problem using Grey Wolf Optimizer, *Neural Computing and Applications*, vol. 27, no. 5, pp. 1301-1316, 2016.
- [73] B. Mandal, P. K. Roy and S. Mandal, Economic load dispatch using krill herd algorithm, *International Journal of Electrical Power & Energy Systems*, vol. 57, pp. 1–10, 2014.
- [74] J. Derrac, S. García, D. Molina, and F. Herrera, A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms, *Swarm and Evolutionary Computation*, vol. 1, pp. 3–18, 2011
- [75] A. Kaveh, *Advances in Metaheuristic Algorithms for Optimal Design of Structures*, Springer International Publishing Switzerland, 2014.
- [76] C. D. Ahrens, *Meteorology Today: An Introduction to Weather, Climate, and the Environment*, Thomson-Brooks/Cole, Belmont, Calif, USA, 7th edition, 2003.
- [77] L. Kirchmayer, *Economic Operation of Power Systems*, New Delhi: Wiley Eastern Limited, first ed., 1979.
- [78] PJM, *A review of generation compensation and cost elements in the PJM markets*, PJM, Pennsylvania, 2009.
- [79] F. Oliviera, C. Ruiz, and A. Conejo, Contract design and supply chain coordination in the electricity industry, *European Journal of Operational Research*, vol. 227, no. 3, pp. 527-537, 2013.

[80] N. Gülpınar, and F. S. Oliveira, Analysis of relationship between forward and spot markets in oligopolies under demand and cost uncertainties, *Computational Management Science*, vol. 11, no. 3, pp. 267-283, 2014.

[81] J. Hazra, and A. K. Sinha, A multi-objective power flow using particle swarm optimization, *International Transactions on Electrical energy systems*, vol. 21, no. 1, pp. 1028-1045, 2011.

12. PUBLIKOVANI RADOVI NA TEMU DOKTORSKE DISERTACIJE

- [1] M. Jevtić, N. Jovanović and J. Radosavljević, Solving combined economic emission dispatch problem using Adaptive Wind Driven Optimization, *Turkish Journal Of Electrical Engineering And Computer Sciences*, 2018. DOI: 10.3906/elk-1711-339 (JCR 121/133, IF: 0,578).
- [2] M. Jevtić, N. Jovanović, J. Radosavljević and D. Klimenta, Moth Swarm Algorithm for Solving Combined Economic and Emission Dispatch Problem, *Elektronika ir Elektrotechnika*, vol. 23, no. 5, pp. 21-28, 2017. (JCR 207/262, IF: 0,859).
- [3] M. Jevtić, N. Jovanović i J. Radosavljević, Primena genetskog algoritma u optimizaciji lanca snabdevanja, *XIV Međunarodni naučno-stručni simpozijum INFOTEH-JAHORINA 2015*, Jahorina, Bosna i Hercegovina, Zbornik radova, 2015, pp. 762 – 766.
- [4] M. Jevtić, N. Jovanović and J. Radosavljević, Application of hybrid PSO-GSA algorithm for three stage supply chain network optimization, *Proceedings of International Scientific Conference UNITECH 2015* Gabrovo, Gabrovo, Bulgaria, 2015, pp. 383 – 388.
- [5] M. Jevtić, N. Jovanović and J. Radosavljević, Application of gravitational search algorithm and genetic algorithm on three stage supply chain network model, *Informacione tehnologije, obrazovanje i preduzetništvo ITOP16*, Čačak, Srbija, Zbornik radova, 2016, pp. 67 – 79.
- [6] M. Jevtić, Primena genetičkog algoritma u optimizaciji u upravljanju lancima snabdevanja preduzeća sa uslužnom delatnošću, *Proceedings of International May Conference on Strategic Management - IMKSM2013*, 24-26 May 2013, Bor, Serbia, pp. 139-145, 2013.

**PRILOG A. TABELE B-LOSS MATRICA I KOEFICIJENATA
TROŠKOVA GORIVA I EMISIJE GASOVA**

Tabela A 1. *B-loss* matrice za primenjeni test sistem [46].

Matrica	Elementi matrice
B	$\begin{bmatrix} 0,1382 & -0,0299 & 0,0044 & -0,0022 & -0,0010 & -0,0008 \\ -0,0299 & 0,0487 & -0,0025 & 0,0004 & 0,0016 & 0,0041 \\ 0,0044 & -0,0025 & 0,0182 & -0,0070 & -0,0066 & -0,0066 \\ -0,0022 & 0,0004 & -0,0070 & 0,0137 & 0,0050 & 0,0033 \\ -0,0010 & 0,0016 & -0,0066 & 0,0050 & 0,0109 & 0,0005 \\ -0,0008 & 0,0041 & -0,0066 & 0,0033 & 0,0005 & 0,0244 \end{bmatrix}$
B_0	$[-0,0107 \quad 0,0060 \quad -0,0017 \quad 0,0009 \quad 0,0002 \quad 0,0030]$
B_{00}	$[0,00098573]$

Tabela A2. Koeficijenti troškova goriva, koeficijenti emisije NO_x gasova i ograničenja snage generatora za test sistem 1.

g	a_g	b_g	c_g	α_g	β_g	η_g	ζ_g	λ_g	P_g^{\min}	P_g^{\max}
1	10	200	100	4,091e-2	-5,554e-2	6,490e-2	2,0e-4	2,857	5	150
2	10	150	120	2,543e-2	-6,047e-2	5,638e-2	5,0e-4	3,333	5	150
3	20	180	40	4,258e-2	-5,094e-2	4,586e-2	1,0e-6	8,0	5	150
4	10	100	60	5,326e-2	-3,550e-2	3,380e-2	2,0e-3	2,0	5	150
5	20	180	40	4,258e-2	-5,094e-2	4,586e-2	1,0e-6	8,0	5	150
6	10	150	100	6,131e-2	-5,555e-2	5,151e-2	1,0e-5	6,667	5	150

Tabela A3. Koeficijenti troškova goriva, koeficijenti emisije NO_x i SO_x gasova i ograničenja snage generatora za test sistem 2.

g	a_g	b_g	c_g	α_{gSO_x}	β_{gSO_x}	η_{gSO_x}	α_{gNO_x}	β_{gNO_x}	η_{gNO_x}	P_g^{\min}	P_g^{\max}
1	561	7,9200	0,001562	0,5783298	0,00816466	1,6103e-6	0,043732540	-9,4868099e-5	1,4721848e-7	150	600
2	310	7,8500	0,001940	0,3515338	0,00891174	2,1999e-6	0,055821713	-9,7252878e-5	3,0207577e-7	100	400
3	78	7,9700	0,004820	0,0884504	0,00903782	5,4658e-6	0,027731524	-3,5373734e-4	1,9338531e-6	50	200

PRILOG B. TABELE REZULTATA TESTIRANJA ALGORITAMA I GRAFICI KONVERGENCIJE

B.1 Rezultati testiranja algoritama AWDO, MSA, PSO GSA i FA na IEEE test sistemu sa 6 generatora (bez uticaja i sa uticajem ventila) i sa gubicima u sistemu.

Tabela B1 . Rezultati dobijeni primenom algoritma AWDO.

	Slučaj I (bez uticaja ventila)			Slučaj II (sa uticajem ventila)		
	$w = 1$	$w = 0$	$w = 0.5$	$w = 1$	$w = 0$	$w = 0.5$
P_1 (MW)	12,09691	41,09250	22,55426	5,00000	41,09250	5,00000
P_2 (MW)	28,63120	46,36678	35,45564	11,77284	46,36678	18,61854
P_3 (MW)	58,35573	54,44194	57,00525	83,53981	54,44194	80,05706
P_4 (MW)	99,28542	39,03737	74,53983	74,81557	39,03737	74,81317
P_5 (MW)	52,39702	54,44590	54,82118	79,79983	54,44590	77,91437
P_6 (MW)	35,18992	51,54851	41,55653	30,35130	51,54851	28,95097
ΣP_g (MW)	285,95619	286,93300	285,93270	285,27934	286,93300	285,35412
Min.troškovi (\$/h)	605,99837	646,20700	612,25279	635,82242	728,66748	638,92308
Max.troškovi (\$/h)	605,99840	-	-	660.27230	-	-
Sred.troškovi (\$/h)	605,99840	-	-	639,64120	-	-
Std.rezult.trošk. (\$/h)	1,2372e-11	-	-	6,26290	-	-
Min. NO _x (ton/h)	0,220729	0,194179	0,203570	0,226734	0,194179	0,222780
Max. NO _x (ton/h)	-	0,194179	-	-	0,1943055	-
Sred. NO _x (ton/h)	-	0,194179	-	-	0,1941903	-
Std. rezult. NO _x	-	3,6654e-11	-	-	0,0300	-
P_{loss} (MW)	2,55619	3,53300	2,53270	1,87934	3,53300	1,95412
Vreme iteracija (s)	4,6444	6,8428	5,3527	7,3134	6,9214	5,8684
$P_{loss,1}$ (MW)	-0,01944	1,36451	0,23873	-0,01518	1,36451	-0,02603
$P_{loss,2}$ (MW)	0,51879	0,85445	0,65382	0,14558	0,85445	0,28274
$P_{loss,3}$ (MW)	-0,21661	-0,03099	-0,14306	0,09352	-0,03099	0,04324
$P_{loss,4}$ (MW)	1,41106	0,25620	0,82740	0,78184	0,25620	0,79157

$P_{loss,5}$ (MW)	0,41135	0,29312	0,38317	0,60818	0,29312	0,60408
$P_{loss,6}$ (MW)	0,45104	0,79571	0,57265	0,26539	0,79571	0,25852
$P_{s,1}$ (MW)	12,11635	39,72799	22,31553	5,01518	39,72800	5,02603
$P_{s,2}$ (MW)	28,11241	45,51233	34,80182	11,62726	45,51234	18,33580
$P_{s,3}$ (MW)	58,57234	54,47293	57,14831	83,44629	54,47292	80,01382
$P_{s,4}$ (MW)	97,87436	38,78117	73,71243	74,03373	38,78117	74,02160
$P_{s,5}$ (MW)	51,98567	54,15278	54,43801	79,19164	54,15277	77,31030
$P_{s,6}$ (MW)	34,73888	50,75280	40,98388	30,08590	50,75280	28,69245
F_1 (\$/h)	20,25000	109,07095	20,25000	20,25000	126,57464	20,25000
F_2 (\$/h)	29,32246	105,34872	42,08762	33,39503	121,34871	42,08762
F_3 (\$/h)	198,28726	129,85118	189,73924	198,28726	142,70822	189,73924
F_4 (\$/h)	118,39978	58,18086	118,39523	118,40107	70,17169	118,39523
F_5 (\$/h)	189,11173	129,86004	184,52846	189,11173	141,23144	184,52846
F_6 (\$/h)	64,73896	113,89525	61,80804	76,37733	126,63279	61,80804

Tabela B2 . Rezultati dobijeni primenom algoritma MSA.

	Slučaj I (bez uticaja ventila)			Slučaj II (sa uticajem ventila)		
	$w = 1$	$w = 0$	$w = 0.5$	$w = 1$	$w = 0$	$w = 0.5$
P_1 (MW)	12,09792	41,09385	22,55447	5,04056	41,09265	5,03738
P_2 (MW)	28,63365	46,36978	35,45842	11,76832	46,37001	18,32818
P_3 (MW)	58,35230	54,44382	57,00284	83,52900	54,44302	79,14425
P_4 (MW)	99,28565	39,03450	74,53688	74,89400	39,03425	74,80954
P_5 (MW)	52,39954	54,44226	54,82292	79,80155	54,44880	78,47012
P_6 (MW)	35,18722	51,54892	41,55725	30,24587	51,54425	29,57285
ΣP_g (MW)	285,95627	286,93313	285,93278	285,27930	286,93298	285,36232
Min.troškovi (\$/h)	605,99837	646,21155	612,25436	635,84799	728,66962	639,11337
Max.troškovi (\$/h)	605,99841	-	-	658,12961	-	-
Sred.troškovi (\$/h)	605,99838	-	-	640,31740	-	-
Std.rezult.trošk. (\$/h)	9,2426e-06	-	-	6,982008	-	-
Min. NO _x (ton/h)	0,220729	0,194179	0,203569	0,226764	0,194179	0,222607
Max. NO _x (ton/h)	-	194,17852	-	-	0,194179	-

Sred. NO _x (ton/h)	-	194,17851	-	-	0,194179	-
Std. rezult. NO _x	-	2,2374e-06	-	-	1,10051e-6	-
P_{loss} (MW)	2,55627	3,53313	2,53278	1,87930	3,53298	1,96232
Vreme iteracija (s)	6,37231	8,47070	7,07522	2,10150	2,08519	1,84084
$P_{loss,1}$ (MW)	-0,01943	1,36460	0,23872	-0,01515	1,36448	-0,02590
$P_{loss,2}$ (MW)	0,51886	0,85455	0,65392	0,14532	0,85457	0,27684
$P_{loss,3}$ (MW)	-0,21664	-0,03095	-0,14308	0,09362	-0,03096	0,02436
$P_{loss,4}$ (MW)	1,41110	0,25615	0,82735	0,78318	0,25616	0,79974
$P_{loss,5}$ (MW)	0,41140	0,29307	0,38319	0,60850	0,29314	0,61758
$P_{loss,6}$ (MW)	0,45099	0,79571	0,57267	0,26383	0,79559	0,26970
$P_{s,1}$ (MW)	12,11735	39,72925	22,31575	5,05571	39,72816	5,06328
$P_{s,2}$ (MW)	28,11479	45,51523	34,8045	11,62300	45,51544	18,05134
$P_{s,3}$ (MW)	58,56894	54,47477	57,14592	83,43538	54,47399	79,11989
$P_{s,4}$ (MW)	97,87455	38,77835	73,70953	74,11082	38,77809	74,00980
$P_{s,5}$ (MW)	51,98814	54,14919	54,43973	79,19305	54,15566	77,85254
$P_{s,6}$ (MW)	34,73623	50,75321	40,98458	29,98204	50,74866	29,30314

Tabela B3. Rezultati dobijeni primenom algoritma PSO GSA.

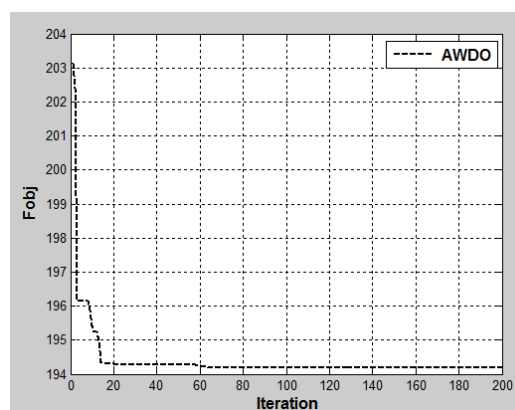
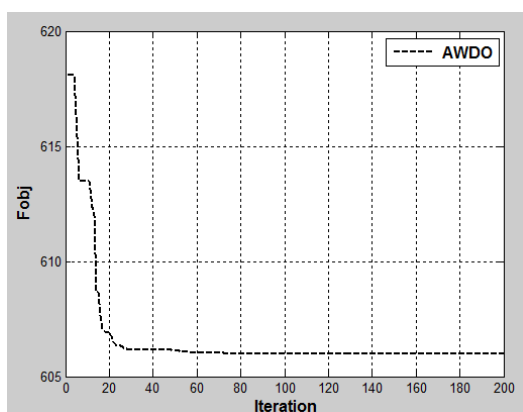
	Slučaj I (bez uticaja ventila)			Slučaj II (sa uticajem ventila)		
	$w = 1$	$w = 0$	$w = 0.5$	$w = 1$	$w = 0$	$w = 0.5$
P_1 (MW)	12,09691	41,09250	22,55426	5,00000	41,09250	5,00000
P_2 (MW)	28,63120	46,36678	35,45565	11,72104	46,36678	18,98360
P_3 (MW)	58,35572	54,44194	57,00525	83,53982	54,44194	79,73343
P_4 (MW)	99,28542	39,03737	74,53983	74,81341	39,03737	74,81317
P_5 (MW)	52,39702	54,44590	54,82118	79,79983	54,44590	77,95474
P_6 (MW)	35,18992	51,54851	41,55653	30,40510	51,54851	28,87633
ΣP_g (MW)	285,95619	286,93300	285,93270	285,27919	286,93300	285,36127
Min.troškovi (\$/h)	605,99837	646,20700	612,25279	635,82289	728,66748	616,67422
Max.troškovi (\$/h)	643,19300	-	-	710,54104	-	-
Sred.troškovi (\$/h)	620,38469	-	-	662,28337	-	-
Std.rezult.trošk. (\$/h)	13,98400	-	-	20,73610	-	-

Min. NO _x (ton/h)	0,220729	0,194179	0,203570	0,226744	0,194179	0,222590
Max. NO _x (ton/h)	-	0,222654	-	-	2,155178	-
Sred. NO _x (ton/h)	-	0,202897	-	-	2,012987	-
Std. rezult. NO _x	-	6,395940	-	-	5,714380	-
P_{loss} (MW)	2,55619	3,53300	2,53270	1,87919	3,53300	1,96127
Vreme iteracija (s)	3,09460	2,86217	3,12065	3,45576	3,35833	3,49308
$P_{loss,1}$ (MW)	-0,01944	1,36451	0,23873	-0,01510	1,36451	-0,02664
$P_{loss,2}$ (MW)	0,51879	0,85445	0,65382	0,14474	0,85445	0,29145
$P_{loss,3}$ (MW)	-0,21661	-0,03099	-0,14306	0,09335	-0,03099	0,03789
$P_{loss,4}$ (MW)	1,41106	0,25620	0,82740	0,78191	0,25620	0,79334
$P_{loss,5}$ (MW)	0,41135	0,29312	0,38317	0,60813	0,29312	0,60681
$P_{loss,6}$ (MW)	0,45104	0,79571	0,57265	0,26616	0,79571	0,25842
$P_{s,1}$ (MW)	12,11635	39,72799	22,31553	5,01510	39,72800	5,02664
$P_{s,2}$ (MW)	28,11241	45,51233	34,80183	11,57630	45,51234	18,69216
$P_{s,3}$ (MW)	58,57233	54,47293	57,14831	83,44647	54,47292	79,69554
$P_{s,4}$ (MW)	97,87436	38,78117	73,71243	74,03150	38,78117	74,01983
$P_{s,5}$ (MW)	51,98567	54,15278	54,43801	79,19170	54,15277	77,34792
$P_{s,6}$ (MW)	34,73888	50,7528	40,98388	30,13893	50,75280	28,61790


Tabela B4. Rezultati dobijeni primenom algoritma FA.

	Slučaj I (bez uticaja ventila)			Slučaj II (sa uticajem ventila)		
	$w = 1$	$w = 0$	$w = 0.5$	$w = 1$	$w = 0$	$w = 0.5$
P_1 (MW)	12,09598	41,09174	22,55472	5,00003	41,09216	5,00006
P_2 (MW)	28,63132	46,36671	35,45571	11,50678	46,36613	18,54154
P_3 (MW)	58,35600	54,44188	57,00582	83,53940	54,44275	80,31253
P_4 (MW)	99,28554	39,03732	74,53881	75,24218	39,03679	74,81331
P_5 (MW)	52,39786	54,44646	54,82088	79,79965	54,44663	77,88626
P_6 (MW)	35,18949	51,54884	41,55675	30,19336	51,54848	28,79678
ΣP_g (MW)	285,95619	286,93295	285,93270	285,28139	286,93295	285,35048
Min.troškovi (\$/h)	605,99837	646,20656	612,25326	635,85531	728,66693	638,7942

Max.troškovi (\$/h)	606,40143	-	-	650,31679	-	-
Sred.troškovi (\$/h)	606,01185	-	-	639,38531	-	-
Std.rezult.trošk. (\$/h)	0,0735811	-	-	4,478271	-	-
Min. NO _x (ton/h)	0,220730	0,194179	0,203570	0,227032	0,194179	0,222911
Max. NO _x (ton/h)	-	0,194179	-	-	0,194179	-
Sred. NO _x (ton/h)	-	0,194179	-	-	0,194179	-
Std. rezult. NO _x	-	1,1483e-05	-	-	1,973e-07	-
P_{loss} (MW)	2,55619	3,53295	2.53270	1,88139	3,53295	1,95048
Vreme iteracija (s)	7,17511	8,79489	7.70115	7,32999	8,79802	7,44865
$P_{loss,1}$ (MW)	-0,01945	1,36444	0.23875	-0,01482	1,36449	-0,02585
$P_{loss,2}$ (MW)	0,51880	0,85446	0.65382	0,14112	0,85443	0,28070
$P_{loss,3}$ (MW)	-0,21662	-0,03099	-0.14305	0,09245	-0,03098	0,04818
$P_{loss,4}$ (MW)	1,41107	0,25620	0.82737	0,79013	0,25619	0,78972
$P_{loss,5}$ (MW)	0,41136	0,29313	0.38316	0,60948	0,29313	0,60216
$P_{loss,6}$ (MW)	0,45103	0,79572	0.57265	0,26303	0,79570	0,25556
$P_{s,1}$ (MW)	12,11543	39,72730	22.31597	5,01485	39,72768	5,02591
$P_{s,2}$ (MW)	28,11252	45,51225	34.80189	11,36566	45,51171	18,26083
$P_{s,3}$ (MW)	58,57262	54,47287	57.14887	83,44695	54,47373	80,26435
$P_{s,4}$ (MW)	97,87447	38,78112	73.71144	74,45205	38,78060	74,02359
$P_{s,5}$ (MW)	51,9865	54,15333	54.43772	79,19017	54,15350	77,28410
$P_{s,6}$ (MW)	34,73846	50,75312	40.98410	29,93033	50,75278	28,54122




(a)



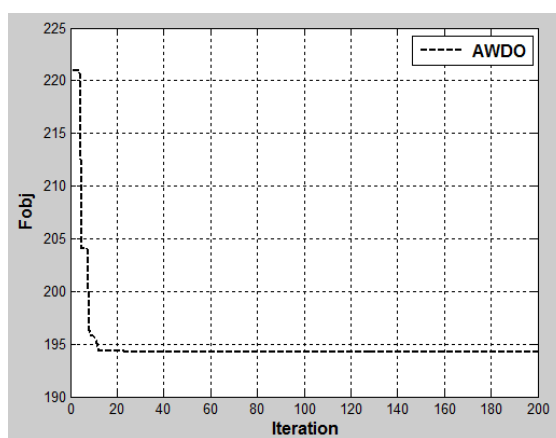
(b)

(c)


Slika B1. Krive konvergencije algoritma AWDO za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)




(b)




(c)


Slika B2. Krive konvergencije algoritma AWDO za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)




(b)




(c)


Slika B3. Krive konvergencije algoritma MSA za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)




(b)




(c)


Slika B4. Krive konvergencije algoritma MSA za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)




(b)

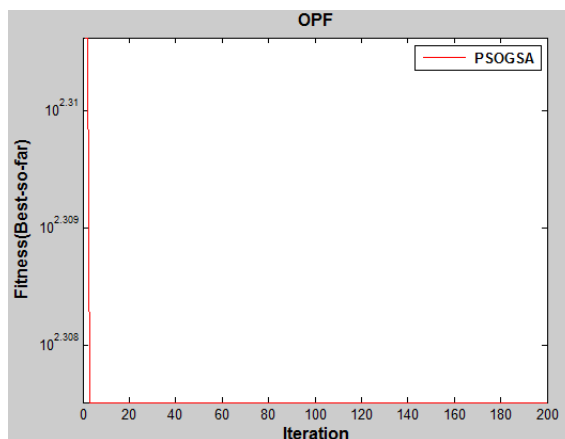


(c)

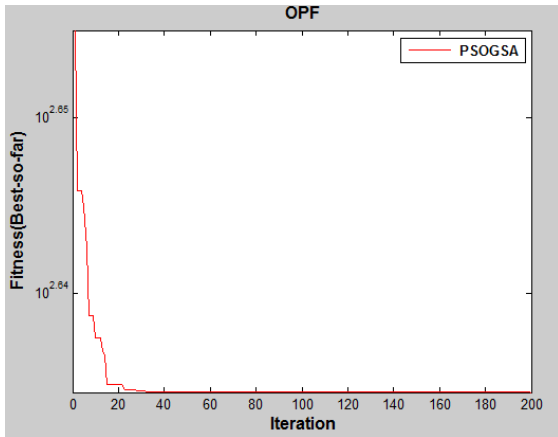
Slika B5. Krive konvergencije algoritma PSO GSA za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)




(b)

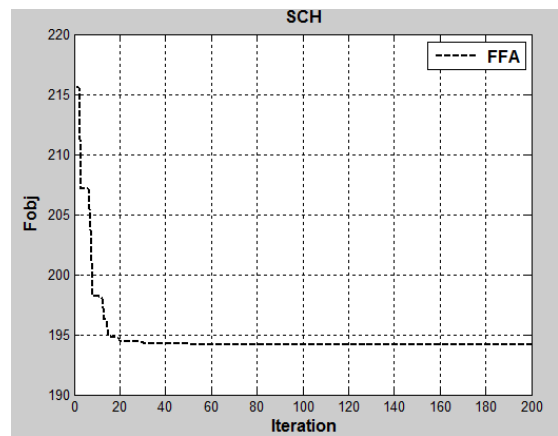


(c)


Slika B6. Krive konvergencije algoritma PSO GSA za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)




(b)




(c)


Slika B7. Krive konvergencije algoritma FA za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.



(a)



(b)



(c)

Slika B8. Krive konvergencije algoritma FA za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije NO_x gasova, istovremeno.

B.2 Rezultati testiranja algoritama AWDO, MSA, PSO GSA i FA na IEEE test sistemima sa 3 i sa 6 generatora, bez gubitaka u sistemu i bez uticaja ventila

Tabela B5. Rezultati dobijeni primenom algoritma AWDO.

	IEEE test sistem sa 3 generatora				IEEE test sistem sa 6 generatora		
	$w = 1$	$w = 0$ (NO _x minimizacija)	$w = 0$ (SO _x minimizacija)	$w = 0,5$	$w = 1$	$w = 0$	$w = 0,5$
P_1 (MW)	393,16984	498,32435	542,61948	495,33928	10,97193	40,60739	23,22985
P_2 (MW)	334,60376	246,80875	227,39221	249,88639	29,97661	45,90689	36,03388
P_3 (MW)	122,22640	104,86690	79,98832	104,77433	52,42983	53,79386	53,88179
P_4 (MW)	-	-	-	-	101,61988	38,29530	74,57677
P_5 (MW)	-	-	-	-	52,42983	53,79386	53,88180
P_6 (MW)	-	-	-	-	35,97193	51,00271	41,79591
ΣP_g (MW)	850,00000	850,00000	850,00000	850,00000	283,40001	283,40001	283,40000
Min.troškovi (\$/h)	8194,35612	8228,03386	8260,14182	8226,05270	600,11141	638,27344	606,79829
Max.troškovi (\$/h)	8194,35612	-	-	-	600,11141	-	-
Sred.troškovi (\$/h)	8194,35612	-	-	-	600,11141	-	-
Min.NO _x emisija (ton/h)	0,099677	0,095138	0,096738	0,095143	0,22214	0,19420	0,20329
Max.NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Sred.NO _x emisija(ton/h)	-	0,095138	-	-	-	0,19420	-
Min.SO _x emisija (ton/h)	8,891853	8,828221	8,820849	8,828920	-	-	-
Max. SO _x emisija(ton/h)	8,891853	8,828221	8,820849	-	-	-	-

Tabela B6. Rezultati dobijeni primenom algoritma MSA.

	IEEE test sistem sa 3 generatora				IEEE test sistem sa 6 generatora		
	$w = 1$	$w = 0$ (NO _x minimizacija)	$w = 0$ (SO _x minimizacija)	$w = 0,5$	$w = 1$	$w = 0$	$w = 0,5$
P_1 (MW)	393,16985	498,32435	542,61946	495,33897	10,97208	40,60759	23,22879
P_2 (MW)	334,60375	246,80875	227,39222	249,88672	29,97541	45,90770	36,03285
P_3 (MW)	122,22640	104,86690	79,98831	104,77431	52,42752	53,78577	53,88251
P_4 (MW)	-	-	-	-	101,61949	38,29603	74,57988
P_5 (MW)	-	-	-	-	52,43134	53,79817	53,88151
P_6 (MW)	-	-	-	-	35,97416	51,00473	41,79446
ΣP_g (MW)	850,00000	850,00000	850,00000	850,00000	283,40000	283,40000	283,40000
Min.troškovi goriva (\$/h)	8194,35612	8228,03386	8260,14181	8226,05250	600,11141	638,27388	606,79671
Max.troškovi goriva (\$/h)	8194,35612	-	-	-	600,11155	-	-
Sred.troškovi goriva (\$/h)	8194,35612	-	-	-	600,11142	-	-
Std.rezultata troškova	4,00e-12	-	-	-	2,64411e-5	-	-
Min. NO _x emisija (ton/h)	0,099677	0,095138	0,096738	0,095143	0,22214	0,19420	0,20329
Max. NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Sred. NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Std.rezult.NO _x emisije	-	1,14e-15	-	-	-	1,91439e-9	-
Min. SO _x emisija (ton/h)	8,891853	8,828221	8,820849	8,828920	-	-	-
Max. SO _x emisija (ton/h)	-	-	8,820849	-	-	-	-
Std.rezult.SO _x emisije	-	-	8,73e-16	-	-	-	-

Tabela B7. Rezultati dobijeni primenom algoritma PSO GSA.


	IEEE test sistem sa 3 generatora				IEEE test sistem sa 6 generatora		
	$w = 1$	$w = 0$ (NO _x minimizacija)	$w = 0$ (SO _x minimizacija)	$w = 0,5$	$w = 1$	$w = 0$	$w = 0,5$
P_1 (MW)	393,16970	498,32490	542,61978	495,33913	10,97297	40,60661	23,23151
P_2 (MW)	334,60365	246,80838	227,39194	249,88662	29,97810	45,90961	36,03278
P_3 (MW)	122,22665	104,86671	79,98828	104,77424	52,43236	53,79564	53,88141
P_4 (MW)	-	-	-	-	101,61542	38,29569	74,57682
P_5 (MW)	-	-	-	-	52,42861	53,79188	53,87919
P_6 (MW)	-	-	-	-	35,97254	51,00056	41,79829
ΣP_g (MW)	850,00000	850,00000	850,00000	850,00000	283,40000	283,40000	283,40000
Min.troškovi goriva (\$/h)	8194,35612	8228,03420	8260,14209	8226,05259	600,11141	638,27308	606,79877
Max.troškovi goriva (\$/h)	8194,35612	-	-	-	600,11141	-	-
Sred.troškovi goriva (\$/h)	8194,35612	-	-	-	600,11141	-	-
Std.rezultata troškova	2,38e-8	-	-	-	-	-	-
Min. NO _x emisija (ton/h)	0,099677	0,095138	0,096738	0,095143	0,22214	0,19420	0,20329
Max. NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Sred. NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Std.rezult.NO _x emisije	-	2,93e-12	-	-	-	-	-
Min. SO _x emisija (ton/h)	8,891854	8,828221	8,820849	8,828920	-	-	-
Max. SO _x emisija (ton/h)	-	-	8,820849	-	-	-	-

Std.rezult.SO _x emisije	-	-	1,80e-11	-	-	-	-
------------------------------------	---	---	----------	---	---	---	---


Tabela B8. Rezultati dobijeni primenom algoritma FA.

	IEEE test sistem sa 3 generatora				IEEE test sistem sa 6 generatora		
	w = 1	w = 0 (NO _x minimizacija)	w = 0 (SO _x minimizacija)	w = 0,5	w = 1	w = 0	w = 0,5
P ₁ (MW)	393,16899	498,32437	542,61939	495,33897	10,97305	40,60647	23,22995
P ₂ (MW)	334,60454	246,80884	227,39212	249,88666	29,97669	45,90736	36,03452
P ₃ (MW)	122,22647	104,86680	79,98849	104,77437	52,42828	53,79332	53,88077
P ₄ (MW)	-	-	-	-	101,62040	38,29584	74,57719
P ₅ (MW)	-	-	-	-	52,43057	53,79497	53,88241
P ₆ (MW)	-	-	-	-	35,97101	51,00205	41,79516
ΣP _g (MW)	850,00000	850,00000	850,00000	850,00000	283,40000	283,40000	283,40000
Min.troškovi goriva (\$/h)	8194,35612	8228,03385	8260,14175	8226,05251	600,11141	638,27247	606,79818
Max.troškovi goriva (\$/h)	8194,35612	-	-	-	6,0011141	-	-
Sred.troškovi goriva (\$/h)	8194,35612	-	-	-	6,0011141	-	-
Std.rezultata troškova	1,37e-9	-	-	-	1,63739e-7	-	-
Min. NO _x emisija (ton/h)	0,099677	0,095138	0,096738	0,095143	0,22214	0,19420	0,20329
Max. NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Sred. NO _x emisija (ton/h)	-	0,095138	-	-	-	0,19420	-
Std.rezult.NO _x emisije	-	1,80e-12	-	-	-	-	-
Min. SO _x emisija (ton/h)	8,891854	8,828221	8,820849	8,828920	-	-	-


Max. SO _x emisija (ton/h)	-	-	8,820849	-	-	-	-
Std.rezult.SO _x emisije	-	-	1,13e-12	-	-	-	-




(a)



(b)




(c)




(d)


Slika B9. Krive konvergencije algoritma AWDO za test sistem sa 3 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno.




(a)



(b)

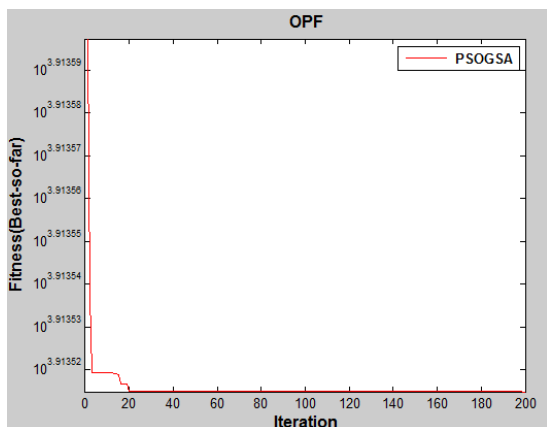


(c)

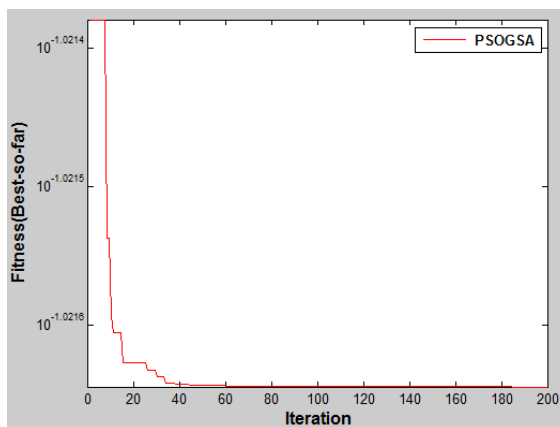


(d)


Slika B10. Krive konvergencije algoritma MSA za test sistem sa 3 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno.




(a)



(b)




(c)




(d)


Slika B11. Krive konvergencije algoritma PSO GSA za test sistem sa 3 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno.




(a)



(b)




(c)




(d)


Slika B12. Krive konvergencije algoritma FA za test sistem sa 3 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno.



(a)




(b)

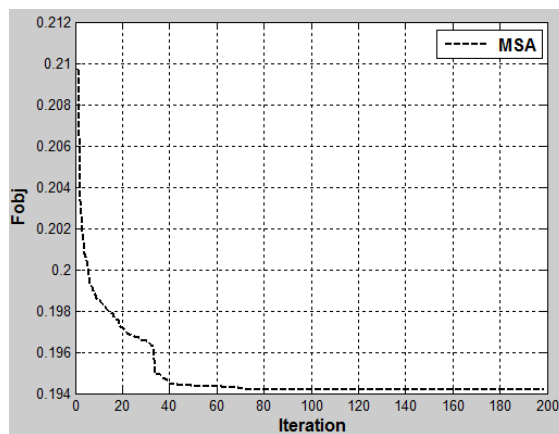


(c)


Slika B13. Krive konvergencije algoritma AWDO za test sistem sa 6 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno.



(a)




(b)




(c)

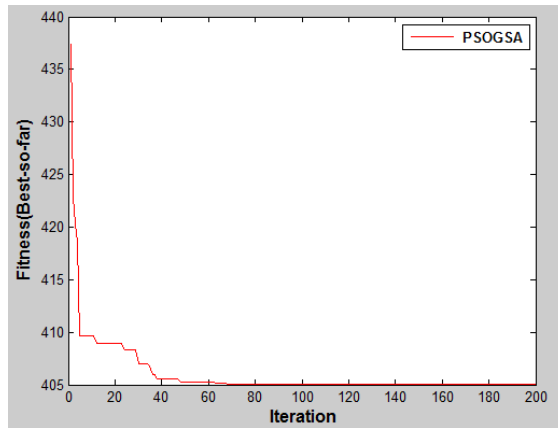
Slika B14. Krive konvergencije algoritma MSA za test sistem sa 6 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno.



(a)




(b)

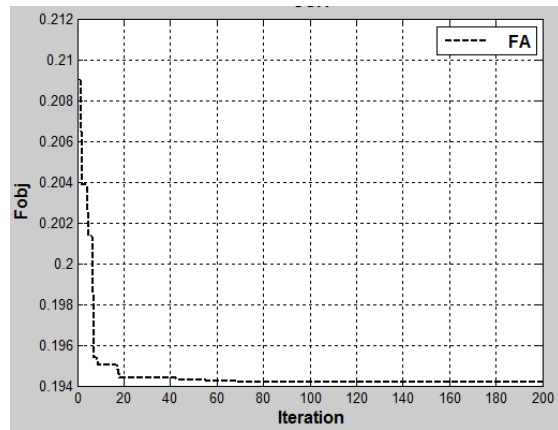


(c)


Slika B15. Krive konvergencije algoritma PSO-GSA za test sistem sa 6 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno.



(a)




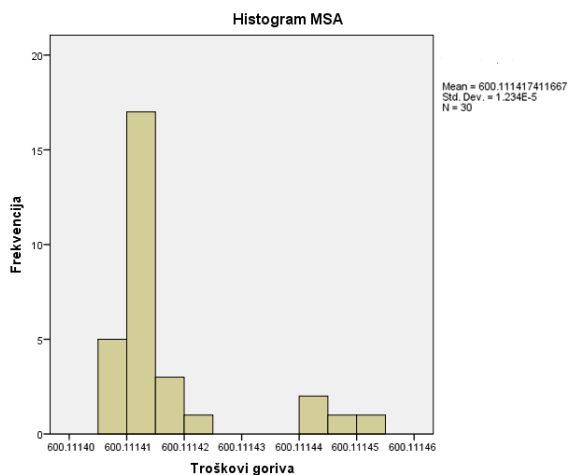



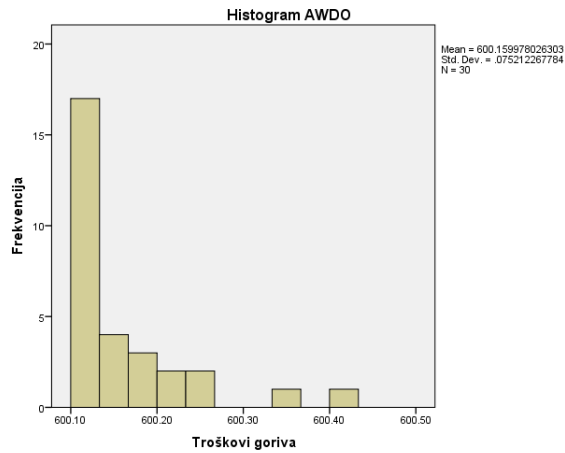
(b)




(c)

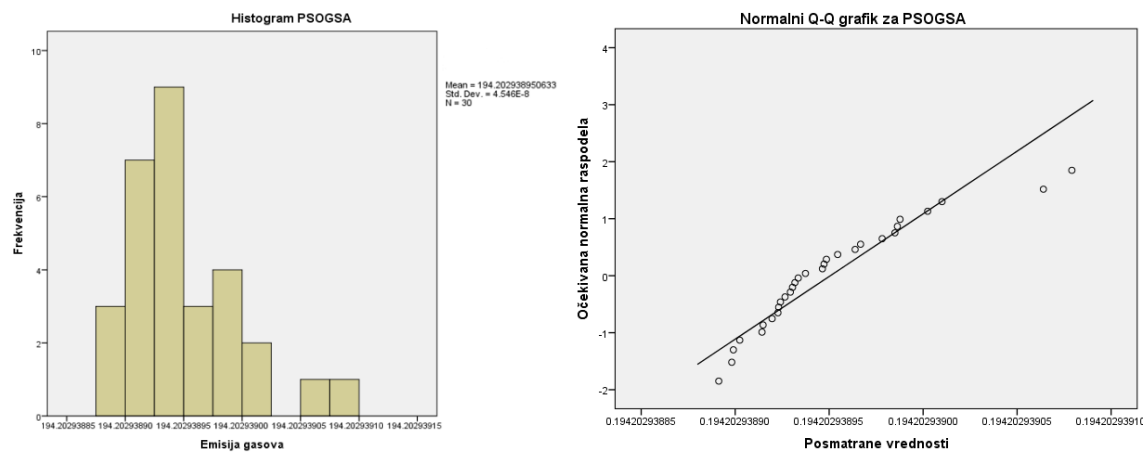
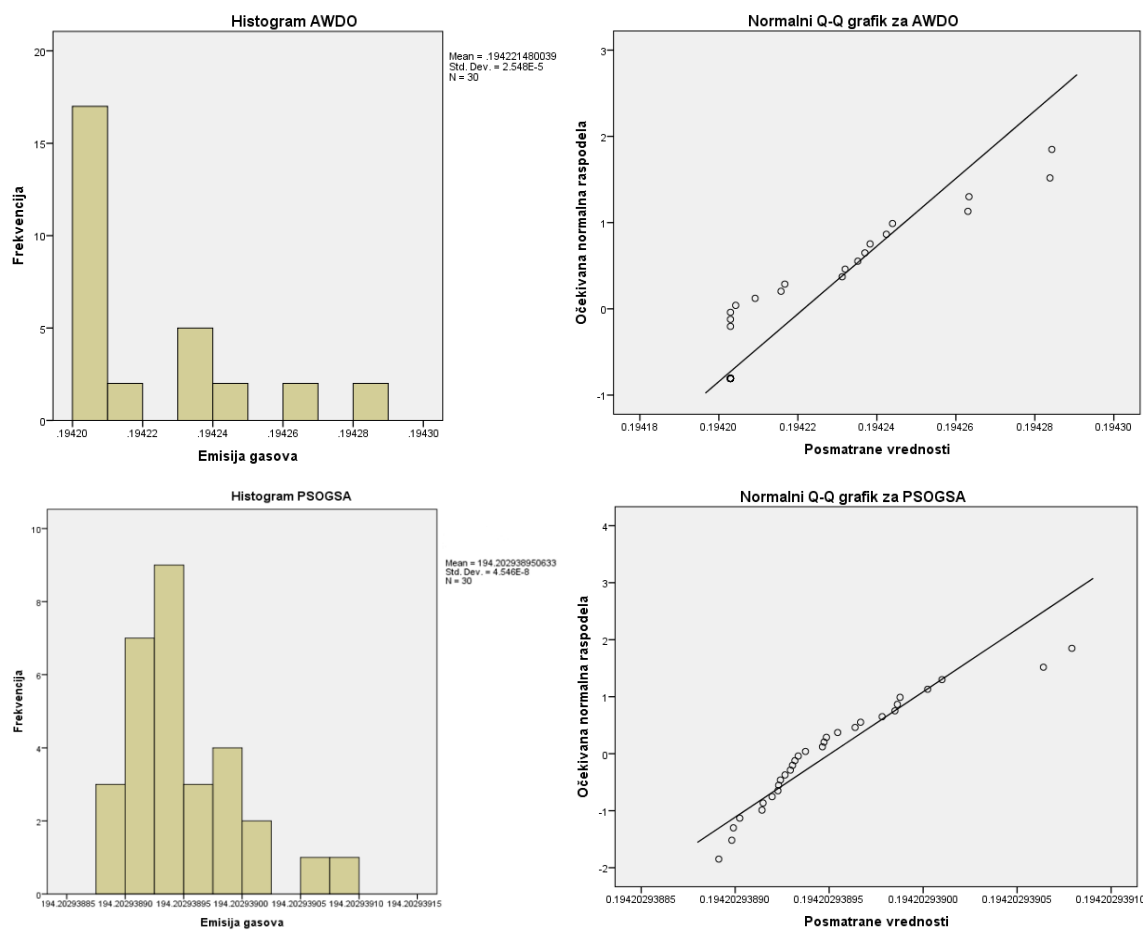
Slika B16. Krive konvergencije algoritma FA za test sistem sa 6 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno.

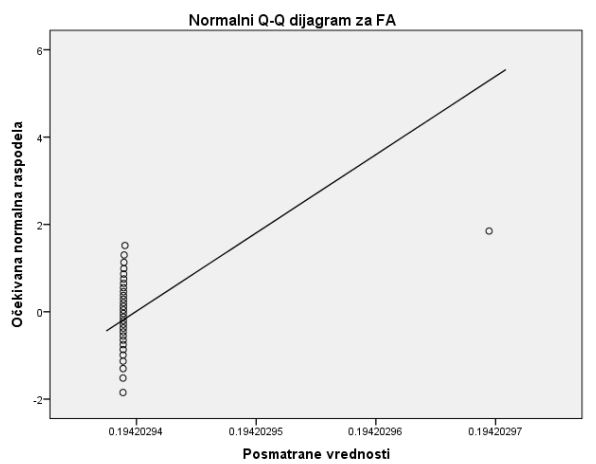
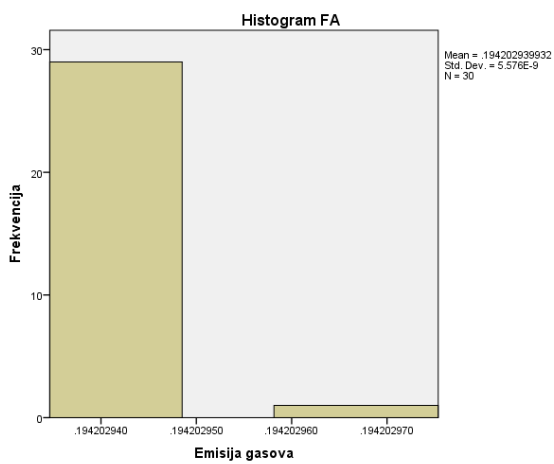

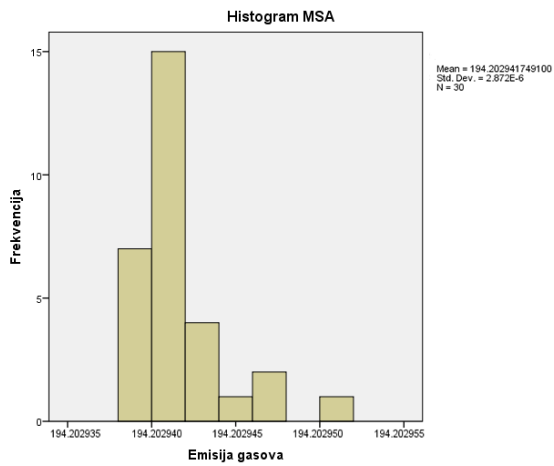
PRILOG C. HISTOGRAMI I Q-Q GRAFICI ALGORITAMA AWDO, PSOĞSA, MSA I FA




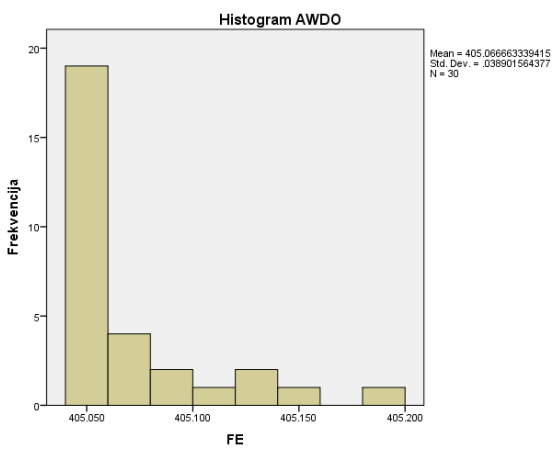



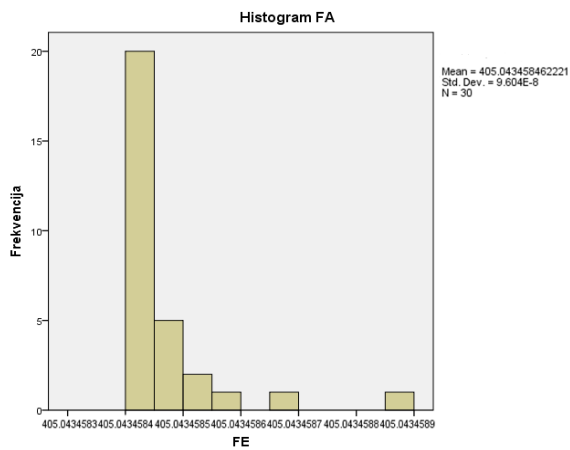


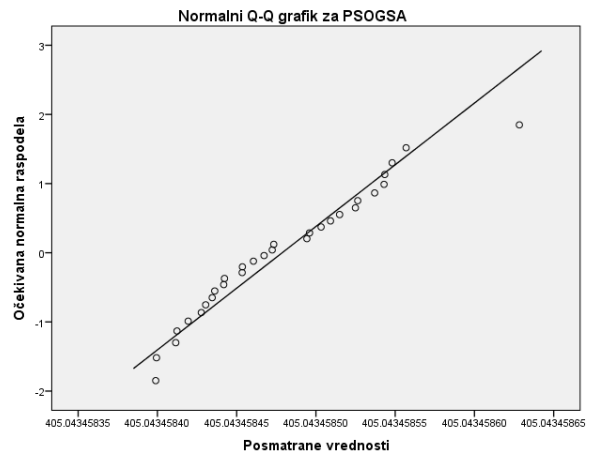
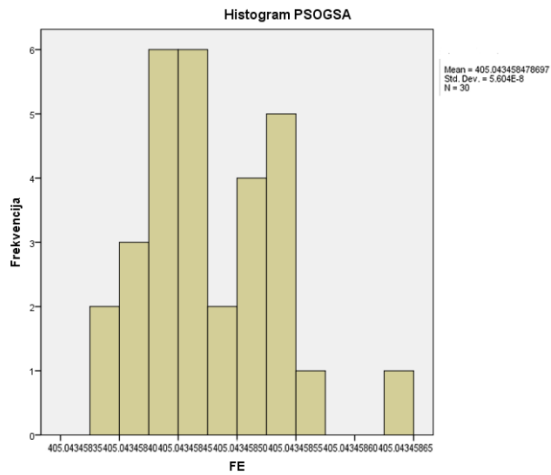
Slika C1. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f1.












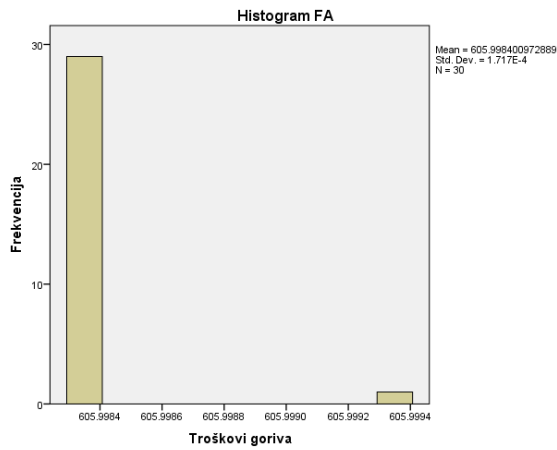
Slika C2. Histogrami i Q-Q grafici algoritama AWDO, PSOGSA, MSA i FA primenjenih na f2.




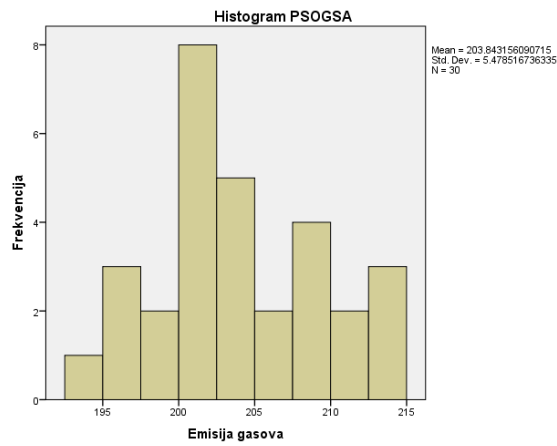

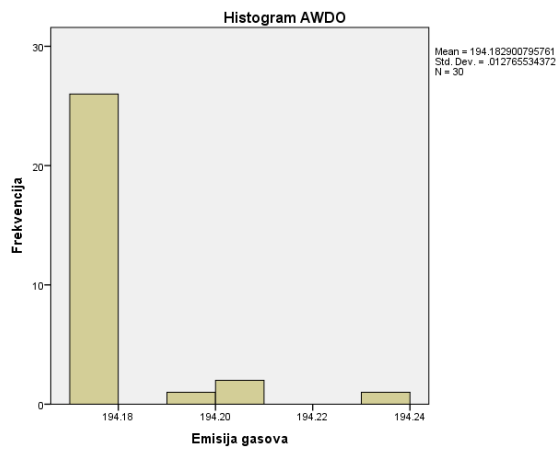



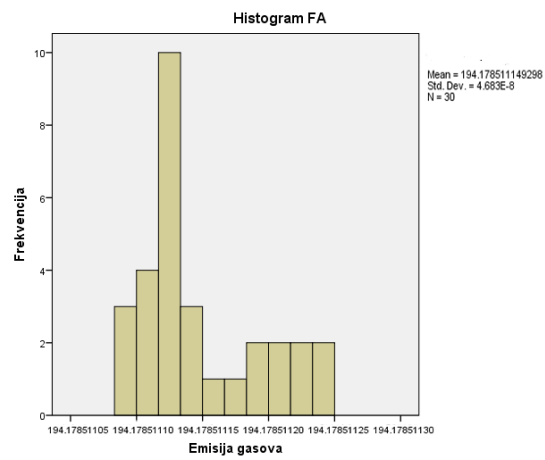

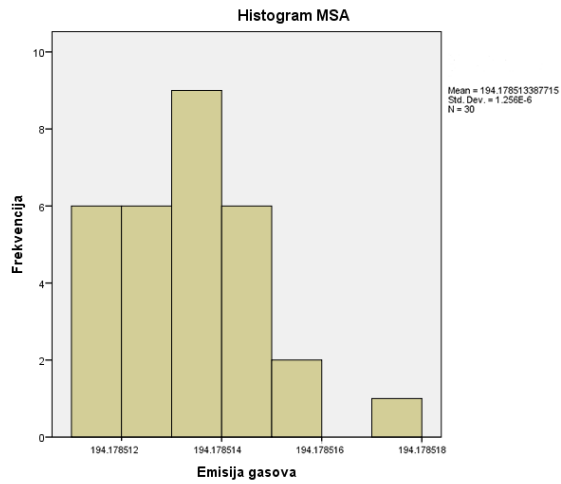
Slika C3. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f3.



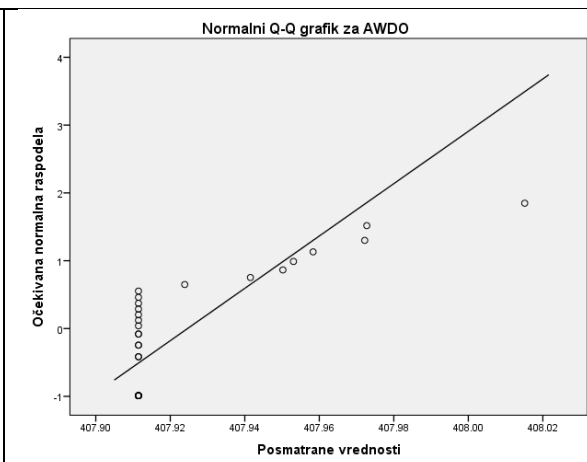
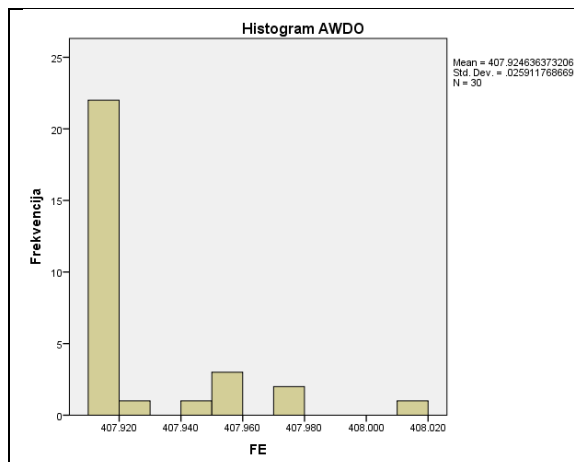


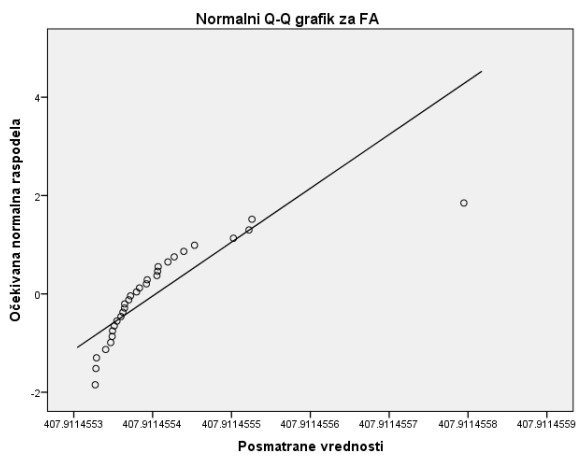


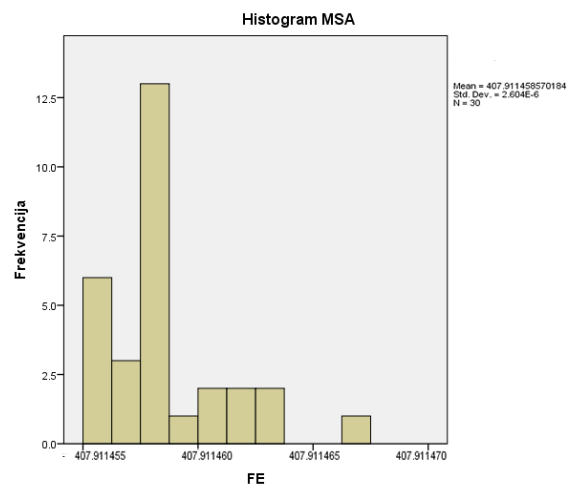

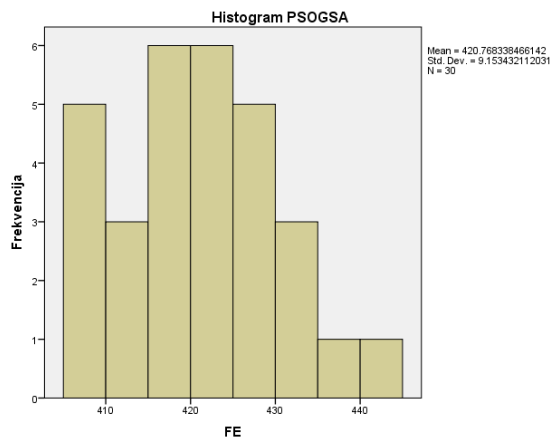
Slika C4. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f4.




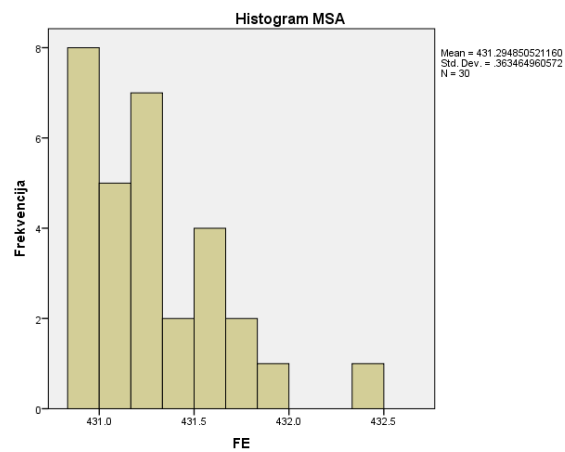

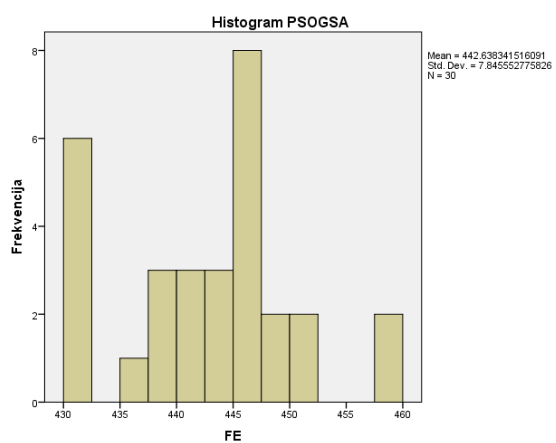
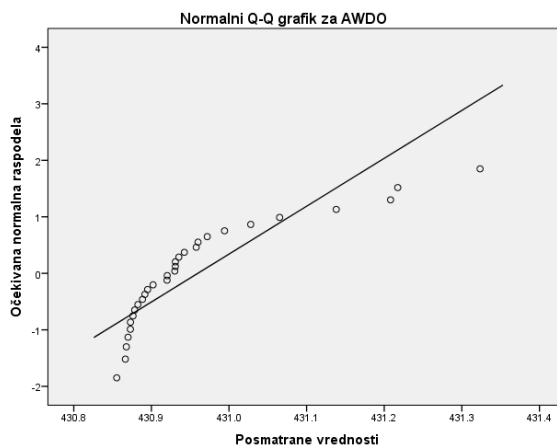
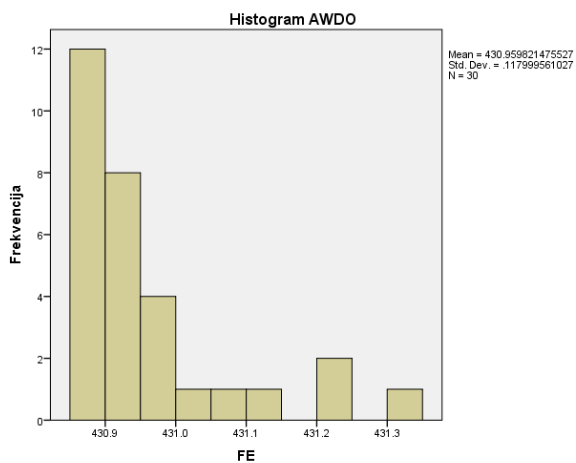


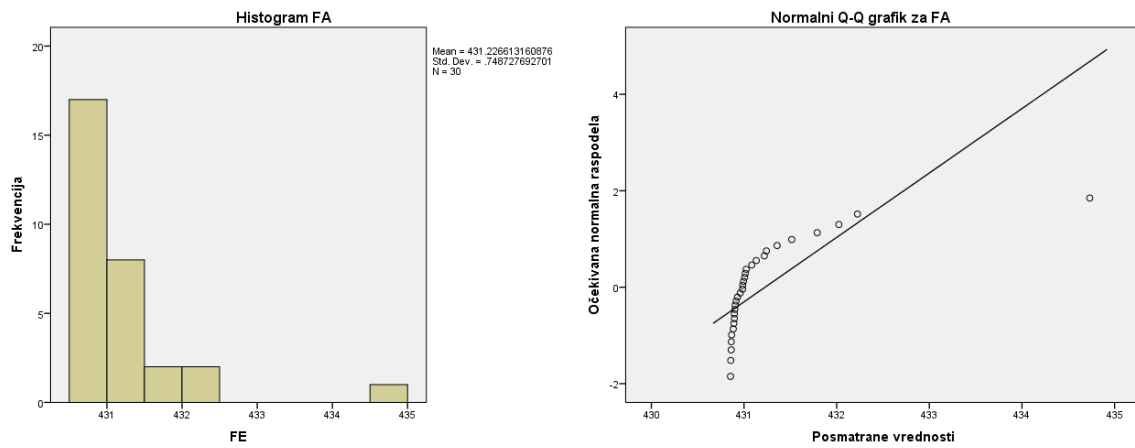
Slika C5. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f5.





Slika C6. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f6.





Slika C7. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f8.

PRILOG D. SKRAĆENICE I OSNOVNE OZNAKE, PREMA REDOSLEDU POJAVLJIVANJA

MA	metaheuristički algoritam
$f(x)$	funkcija vrednosti rešenja $f(x)$
M	broj jedinki u prostoru kandidata rešenja
t	broj iteracija
t_{max}	maksimalni broj iteracija
x	jedinka (kandidat rešenja) u prostoru kandidata rešenja
R^n	n-dimenzionalni prostor realnih brojeva
ERS	ekonomična raspodela snaga (eng. <i>economic dispatch</i>)
MSA	Algoritam roja noćnih leptira (eng. <i>Moth Swarm Algorithm</i>)
AWDO	Adaptivna optimizacija inspirisana vetrom (eng. <i>Adaptive Wind Driven Optimization</i>)
IEEE	Institute of Electrical and Electronics Engineers
benchmark funkcija	reperna funkcija
WDO	Optimizacija inspirisane vetrom (eng. <i>Wind Driven Optimization</i>)
CMAES	Evoluciona strategija adaptacijom matrice kovarijansi (eng. <i>Covariance Matrix Adaptation Evolution Strategy</i>)
DE	Diferencijalna evolucija (eng. <i>Differential Evolution</i>)
BBO	Algoritam inspirisan biogeografijom (eng. <i>Biogeography-based Optimization</i>)
Tribe-MDE	DE modifikovan plemenima (eng. <i>Tribe-Modified Differential Evolution Algorithm</i>)
GA	Genetski algoritam (eng. <i>Genetic Algorithm</i>)
NSGA	Genetski algoritam sortiranja nedominiranih rešenja (eng. <i>Non-dominated Sorting Genetic Algorithm</i>)
MSGGA II	Elitistički genetski algoritam sortiranja nedominiranih rešenja (eng. <i>Elitist Multiobjective Genetic Algorithm</i>)
NPGA	Pareto genetski algoritam sa nišama (eng. <i>Niched Pareto</i>)

	<i>Genetic Algorithm)</i>
PSO	Optimizacija rojevima čestica (eng. <i>Particle Swarm Optimization</i>)
ABC	Algoritam veštačke kolonije pčela (eng. <i>Artificial Bee Colony</i>)
FA	Algoritam svica (eng. <i>Firefly Algorithm</i>)
BFA	Algoritam bakterijskog traganja za hranom (eng. <i>Bacterial Foraging Algorithm</i>)
SOS	Algoritam simbiotskih organizama (eng. <i>Symbiotic Organisms Search</i>)
KHA	Algoritam planktonskih krilova (eng. <i>Krill Herd Algorithm</i>)
GWO	Optimizer sivih vukova (eng. <i>Grey Wolf Optimizer</i>)
PSPSO	Paralelna optimizacija rojevima čestica (eng. <i>Parallel Particle Swarm Optimization</i>)
MOPSO	Višeciljna optimizacija rojevima čestica (eng. <i>Multiobjective Particle Swarm Optimization</i>)
<i>global best</i>	najbolje globalno rešenje
<i>local best</i>	najbolje lokalno rešenje
θ -PSO	θ - optimizacija rojevima čestica (eng. <i>θ-Particle Swarm Optimization</i>)
MA θ -PSO	Modifikovana adaptivna θ -optimizacija rojevima čestica (eng. <i>Modified Adaptive θ-Particle Swarm Optimization</i>)
IABC	Inkrementalna veštačka kolonija pčela (eng. <i>Incremental Artificial Bee Colony</i>)
IABC-LS	Inkrementalna veštačka kolonija pčela sa lokalnim pretraživanjem (eng. <i>Incremental Artificial Bee Colony with Local Search</i>)
PS-ABC	Veštačka kolonija pčela sa verovatnoćom pri izboru rešenja (eng. <i>Probability-Selection Artificial Bee Colony Algorithm</i>)
EPS-ABC	Poboljšana veštačka kolonija pčela sa verovatnoćom pri izboru rešenja (eng. <i>Enhanced Probability-Selection Artificial Bee Colony Algorithm</i>)
HBMO	Optimizacija inspirisana parenjem pčela (eng. <i>Honey Bee</i>

	<i>Mating Optimization)</i>
IHBMO	Interaktivna optimizacija inspirisana parenjem pčela (eng. <i>Interactive Honey Bee Mating Optimization</i>)
GSA	Gravitacioni pretraživački algoritam (eng. <i>Gravitational Search Algorithm</i>)
OGSA	Gravitacioni pretraživački algoritam primenom suprotnih brojeva (eng. <i>Opposition-Based Gravitational Search Algorithm</i>)
PSOGSA	Hibridni algoritam optimizacije rojevima čestica i gravitacionog pretraživačkog algoritma (eng. <i>Hybrid Particle Swarm Optimization and Gravitational Search Algorithm</i>)
HPSO-GSA	Hibridni algoritam optimizacija rojevima čestica - gravitacioni pretraživački algoritam (eng. <i>Hybrid Particle Swarm Optimization - Gravitational Search Algorithm</i>)
BFA	Algoritam bakterijske potrage za hranom (eng. <i>Bacterial Foraging Algorithm</i>)
MBFA	Modifikovani algoritam bakterijske potrage za hranom (eng. <i>Modified Bacterial Foraging Algorithm</i>)
NSBF	Algoritam bakterijske pretrage za hranom sa sortiranjem nedominiranih rešenja (eng. <i>Non-dominated Sorting Bacterial Foraging</i>)
Adaptivni FA	Adaptivni algoritam svica (eng. <i>Self-Adaptive FA</i>)
SOS	Optimizacioni algoritam na bazi pretraživanja simbiotskih organizama (eng. <i>Symbiotic Organisms Search</i>)
FPA	Algoritam polinacije cveta (eng. <i>Flower Polination Algorithm</i>)
CSA	Algoritmu klonske selekcije (eng. <i>Clonal Selection Algorithm</i>)
MOACSA	Višeciljni adaptivni algoritam klonske selekcije (eng. <i>Multi-Objective Adaptive Clonal Selection Algorithm</i>)
SOA	Algoritam optimizacije spiralom (eng. <i>Spiral Optimization Algorithm</i>)
GbSA	Algoritam inspirisan galaksijom (eng. <i>Galaxy based Search Algorithm</i>)

GSO	Optimizacija pretraživanjem grupe (eng. <i>Group Search Optimization</i>)
QOGSO	Optimizacija pretraživanjem kvazigrupe suprotnih elemenata (eng. <i>Quasi-Oppositional Group Search Optimization</i>)
$\alpha, \beta, \delta, \omega, \kappa, \lambda$	oznake vrsta sivih vukova po hijerarhiji u grupi
MCSS	Algoritma inspirisanog kretanjem naelektrisanja pod dejstvom električnih i magnetnih sila (eng. <i>Magnetic Charged System Search Algorithm</i>)
m_j	pozicija pojedinačnog leptira u grupi leptira, kod MSA
$f(m_j)$	fitness funkcija koja definiše intenzitet luminescencije pojedinačnog leptira u grupi
m_{jk}	početna pozicija pojedinačnog leptira u populaciji, kod MSA
m_k^{min}, m_k^{max}	minimalna i maksimalna vrednost m_{jk}
d	dimenzija problema kod MSA
q	ukupan broj jedinki u populaciji kod MSA
σ_k^i	koeficijent varijacije izviđača u k -toj dimenziji i i -toj iteraciji, kod MSA
q_p	broj jedinki izviđača u populaciji kod MSA
μ^i	koeficijent varijacije
c_p	grupa koju sačinjavaju tačke za ukrštanje, kod MSA
$\overline{a_p}$	<i>sub-trail</i> vector
$\overline{m_p}$	<i>host</i> vector
$\overline{m_{p1}}$	komponenta <i>donor</i> vektora
L_{p1}, L_{p2}	varijable generisane pomoću <i>Levi</i> -letova
$Levy(\alpha)$	slučajni hod nastao <i>Levi</i> -letom sa različitim koracima čija raspodela verovatnoće ima tzv. teški rep (eng. <i>heavy tail</i>)
α	indeks <i>Levi</i> α -stabilne raspodele koraka
s	slučajni hod
$L(s)$	<i>Levi</i> α -stabilne raspodele koraka slučajnog hoda s
V_{pk}^i	rešenja putanje hoda (<i>trail</i> rešenja)
P_p	verovatnoća rešenja

fit_p	intenzitet luminescencije
f_p	funkcija cilja za minimizaciju problema
q_f	broj istraživača kod MSA
I	maksimalni broj iteracija, kod MSA
m_p	pozicija istraživača odabrana na osnovu izraza za verovatnoću
	P_p
θ	slučajni broj, kod MSA
q_0	broj posmatrača u populaciji kod MSA
q_G	broj posmatrača koji se kreću prema Gausovoj raspodeli koraka
q_A	broj preostalih posmatrača
ALIM	Mehanizmom asocijativnog učenja (eng. <i>Associative Learning Mechanism</i>)
ε_1	slučajni uzorak dobijen iz Gausove (Normalne) raspodele
size (d)	veličina prve grupe leptira, kod MSA
$best_g$	najbolje globalno rešenje dobijeno u fazi spiralnog kretanja, kod MSA
$\varepsilon_2, \varepsilon_3$	ravnomerno raspoređeni slučajni brojevi u intervalu $[0,1]$, kod MSA
$\vec{\alpha}$	ubrzanje u Drugom Njutnovom zakonu koji se primenjuje za analizu atmosferskih strujanja
ρ	gustina vazduha za parcelu kao elementarni deo vazdušne mase
\vec{F}_i	sile koje deluju na elementarni deo vazdušne mase prema Drugom Njutnovom zakonu
P	pritisak u jednačini stanja idealnog gasa
R	univerzalna gasna konstanta
T	temperatura u jednačini stanja idealnog gasa
\vec{F}_{PG}	sile gradijenta pritiska vazduha pri kretanju vazdušnih masa tokom pojave vetra
\vec{F}_F	sila trenja pri pojavi vetra
\vec{F}_G	gravitaciona sila

\vec{F}_c	Koriolisova sila
∇P	gradijent pritiska vazduha
δV	konačna zapremina vazduha
\vec{u}	brzina vetra
α	koeficijent trenja vazduha
\vec{g}	ubrzanje zemljine teže
Ω	brzina rotacije zemlje
Δt	vremenski korak kod WDO
δV	beskonačno mala zapreminu vazduha
P_{cur}	pritisak vazdušne parcele na trenutnoj lokaciji
P_{opt}	pritisak vazdušne parcele na optimalnoj lokaciji
$\Delta \vec{u}$	promena brzine vazdušne parcele
\vec{u}_{new}	brzina vazdušne parcele u narednoj iteraciji, kod WDO
\vec{u}_{cur}	brzina vazdušne parcele tekućoj iteraciji, kod WDO
\vec{x}	pozicija vazdušne parcele
\vec{x}_{opt}	optimalna vrednost pozicije vazdušne parcele
\vec{x}_{cur}	tekuća vrednost pozicije vazdušne parcele
$\vec{u}_{cur}^{other\ dim}$	nova slučajno izabrana dimenzija iste vazdušne parcele
i	rang parcele dobijen na osnovu vrednosti pritiska, kod WDO
λ	odabrani broj kandidata rešenja u CMAES
\mathbf{x}_i	i -ti kandidat rešenja u CMAES
\mathbf{m}	srednja vrednost Normalne raspodele
σ	veličina koraka iteracionog procesa kod CMAES
N	dimenzija problema
\mathbf{C}	matrica kovarijansi
\mathbf{B}	sopstveni vektor matrice kovarijansi
\mathbf{D}	sopstvena vrednost matrice kovarijansi
μ	najprihvatljiviji broj kandidata rešenja
t	broj iteracije
T	maksimalni broj iteracija
w_i	rekombinaciona težina i -tog najboljeg kandidata rešenja

μ_{eff}	efektivni broj kandidata rešenja posle rekombinacije
\mathbf{P}_σ	evolucionarna putanja (putanje pretraživanja) kod CMAES
c_σ	brzina učenja za regulaciju veličine koraka
d_σ	damping faktor za regulaciju veličine koraka
c_{cov}	brzina učenja pri ažuriranju matrice kovarijansi
c_c	brzina učenja pri ažuriranju matrice kovarijansi ranga jedan
$F_g(P_g)$	funkcija troškova goriva generatorske jedinice u termoelektrani
g	pojedinačni generator kod ERS
P_g	trenutna izlazna snaga generatora g
a_g, b_g i c_g	koeficijenti troškova goriva generatora g
d_g, e_g	koeficijenti udara usled pokretanja ventila u termoelektrani
P_g^{\min}	minimalna snaga generatora g
$E_g(P_g)$	funkcija količina emitovanih gasova generatora g
$\alpha_g, \beta_g, \eta_g, \xi_g, \lambda_g$	koeficijenti emisije generatora g
FE	zbirna funkcija troškova goriva i količine emitovanih gasova generatora g
γ	dimenzioni factor u zbirnoj funkciji FE
w	težinski factor u zbirnoj funkciji FE
G	ukupni broj generatora u termoelektranama pri rešavanju ERS problema
P_g^{\min}	minimalna snaga generatora g
P_g^{\max}	maksimalna snaga generatora g
P_D	ukupna snaga potrošača
P_{loss}	snaga gubitaka u prenosnom sistemu
B_{gj}, B_{0g}, B_{00}	koeficijenti B -loss matrice
δ	zadata dozvoljena greška
P_G^{\lim}	definisana promenljiva vrednost P_G
λ_p	penalni factor
\mathbf{P}_i	vektor pozicije i – tog pretraživačkog agenta u pretraživačkom

	prostoru
P_i^g	elementi vektora \mathbf{P}_i (izlazne snage generatora)
N	broj pretraživačkih agenata
G	balansni generator
$P_{s,g}$	snaga generatora koja se predaje tržištu
$P_{loss,g}$	udeo pojedinačnog generatora u ukupnim gubicima u sistemu
S_p	spot tržište
r	pojedinačni trgovac na tržištu električne energije
R	ukupan broj trgovaca na tržištu električne energije
D	potražnja na tržištu električne energije
P_r	količina snage kupljena od strane trgovca r na spot tržištu
s	utvrđena zajednička spot cena električne snage
d	potrošačka cena električne snage
Π_r	profit trgovca r
Π_g	profit generatora g
κ i φ_r	parametri krive potražnje električne energije
p	vrednosti verovatnoće u statističkim testovima
α	nivo značajnosti u statističkim testovima

PRILOG E. SPISAK TABELA

Broj tabele	Naziv tabele	Broj stranice
Tabela 6.1	Koraci pri rešavanju ERS problema primenom MSA	43
Tabela 6.2	Koraci pri rešavanju ERS problema primenom AWDO	44
Tabela 7.1	Podlašeni parametri algoritama za primenu u test sistemima 1 i 2	52
Tabela 7.2	Najbolja rešenja dobijena primenom algoritma MSA za test sistem 1	52
Tabela 7.3	Minimalne i maksimalne vrednosti i standardne devijacije rezultata dobijenih primenom algoritama MSA, FA i PSO GSA za test sistem 2	52
Tabela 7.4	Najbolja rešenja dobijena primenom algoritma MSA za test sistem 2.	53
Tabela 7.5	Poređenja najboljih rešenja za troškove goriva i emisiju NO _x gasova za test sistem 1	54
Tabela 7.6	Podlašeni parametri algoritama koji su primenjeni na test sistemu	58
Tabela 7.7	Minimalne vrednosti, maksimalne vrednosti i standardne devijacije rezultata i vreme izvršavanja iteracija, dobijeni primenom algoritama: AWDO, MSA, PSO GSA i FA za primenjeni test sistem (Slučaj I)	59
Tabela 7.8	Najbolja rešenja dobijena primenom algoritma AWDO	59
Tabela 7.9	Poređenja najboljih rešenja za test sistem (Slučaj II) dobijenih primenom algoritama AWDO, MSA, PSO GSA i FA	60
Tabela 7.10	Poređenja najboljih rešenja za troškove goriva i emisiju NO _x gasova, dobijenih u ovom radu i u publikovanoj literaturi za test	61

	sistem (Slučaj I)	
Tabela 7.11	Frekvencija konvergencije troškova goriva za Slučaj II, posle 30 puštanja algoritma u rad	62
Tabela 8.1	Količine snaga čija transakcija se vrši sa generatora ka spot tržištu	64
Tabela 8.2	Troškovi i profit generatora	64
Tabela 8.3	Snage i profit trgovaca	65
Tabela 9.1	Opis ERS funkcija koje se minimiziraju	68
Tabela 9.2	Najbolje i srednje vrednosti, standardne devijacije i srednje procentualne greške rezultata, dobijene primenom AWDO, MSA, PSOGSA i FA za test sistem (Slučaj I)	69
Tabela 9.3	p -vrednosti testova normalnosti: <i>Kolmogorov-Smirnov</i> , <i>Shapiro-Wilk</i> i <i>D'Agostino-Pearson</i> .	71
Tabela 9.4	p -vrednosti uparenog t -testa i <i>Wilcoxon</i> testa i razlike srednjih procentualnih grešaka za analizu pojedinačnih funkcija	73
Tabela 9.5	Prave vrednosti p i intervali pouzdanosti za algoritme sa boljim performansama u paru	75
Tabela 9.6	p -vrednosti testova normalnosti za analizu problema sa grupom funkcija	77
Tabela 9.7	p -vrednosti testova <i>Wilcoxon</i> i <i>Friedman</i> za analizu problema sa grupom funkcija	79
Tabela A 1	B -loss matrice za primenjeni test sistem	95
Tabela A2	Koeficijenti troškova goriva, koeficijenti emisije NO_x gasova i ograničenja snage generatora za test sistem 1.	96
Tabela A3	Koeficijenti troškova goriva, koeficijenti emisije NO_x i SO_x gasova i ograničenja snage generatora za test sistem 2	96
Tabela B1	Rezultati dobijeni primenom algoritma AWDO	97
Tabela B2	Rezultati dobijeni primenom algoritma MSA	98

Tabela B3	Rezultati dobijeni primenom algoritma PSO GSA	99
Tabela B4	Rezultati dobijeni primenom algoritma FA	100
Tabela B5	Rezultati dobijeni primenom algoritma AWDO	108
Tabela B6	Rezultati dobijeni primenom algoritma MSA	109
Tabela B7	Rezultati dobijeni primenom algoritma PSO GSA	110
Tabela B8	Rezultati dobijeni primenom algoritma FA	111

PRILOG F. SPISAK SLIKA

Broj slike	Naziv slike	Broj stranice
Slika 3.1	Pravolinijsko kretanje noćnih leptira u odnosu na Mesec (a) i njihovo spiralno kretanje u odnosu na bliski izvor veštačke svetlosti (b)	23
Slika 3.2	Dijagram toka MSA	28
Slika 4.1	Kretanje vazdušnih masa i formiranje vetra	30
Slika 4.2	Dijagram toka AWDO	33
Slika 4.3	Dijagram toka CMAES	37
Slika 6.1	Opšti dijagram toka za rešavanje ERS problema primenom MA	42
Slika 6.2	Šema za razvoj modela lanca snabdevanja na tržištu električne energije spot strukture	46
Slika 7.1	Uporedne krive konvergencije algoritama MSA, PSO GSA i FA u slučajevima minimizacije: (a) emisije NO_x gasova za test sistem 1 bez P_{loss} ; (b) emisije SO_x gasova za test sistem 2 i (c) troškova goriva za test sistem 2	56
Slika 7.2	Komparativne karakteristike konvergencije za algoritme AWDO, MSA, FA i PSO GSA u slučaju minimizacije troškova goriva sa uticajem otvaranja ventila u termoelektrani	61
Slika 9.1	Histogrami i Q-Q grafici algoritama i AWDO, PSO GSA, MSA i FA primenjenih na $f7$	73
Slika 9.2	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na celoj grupi funkcija	78

Slika B1	Krive konvergencije algoritma AWDO za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	102
Slika B2	Krive konvergencije algoritma AWDO za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	103
Slika B3	Krive konvergencije algoritma MSA za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	104
Slika B4	Krive konvergencije algoritma MSA za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	104
Slika B5	Krive konvergencije algoritma PSO GSA za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	105
Slika B6	Krive konvergencije algoritma PSO GSA za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	106
Slika B7	Krive konvergencije algoritma FA za Slučaj I: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	107
Slika B8	Krive konvergencije algoritma FA za Slučaj II: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije NO _x gasova, istovremeno	107
Slika B9	Krive konvergencije algoritma AWDO za test sistem sa 3 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x	113

gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno

- Slika B10 Krive konvergencije algoritma MSA za test sistem sa 3 generatora 114
bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno
- Slika B11 Krive konvergencije algoritma PSO GSA za test sistem sa 3 115
generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno
- Slika B12 Krive konvergencije algoritma FA za test sistem sa 3 generatora 116
bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija emisije SO_x gasova; (d) minimizacija troškova goriva i emisije gasova, istovremeno
- Slika B13 Krive konvergencije algoritma AWDO za test sistem sa 6 117
generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno
- Slika B14 Krive konvergencije algoritma MSA za test sistem sa 6 generatora 118
bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno
- Slika B15 Krive konvergencije algoritma PSO GSA za test sistem sa 6 119
generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO_x gasova; (c) minimizacija troškova goriva i emisije gasova,

istovremeno

Slika B16	Krive konvergencije algoritma FA za test sistem sa 6 generatora bez gubitaka u sistemu i bez uticaja ventila: (a) minimizacija troškova goriva; (b) minimizacija emisije NO _x gasova; (c) minimizacija troškova goriva i emisije gasova, istovremeno	120
Slika C1	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f1.	122
Slika C2	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f2	123
Slika C3	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f3	124
Slika C4	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f4	126
Slika C5	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f5	127
Slika C6	Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f6.	128
Slika C7	Slika C7. Histogrami i Q-Q grafici algoritama AWDO, PSO GSA, MSA i FA primenjenih na f8.	130

Biografija kandidata

Milena Jevtić je rođena 3.05.1986. godine u Zaječaru. Srednju školu je završila odličnim uspehom. Završila je osnovne akademske studije na studijskom programu Informatika Tehničkog fakulteta u Boru Univerziteta u Beogradu 2012. godine, sa prosečnom ocenom 8,10. Master akademske studije na studijskom programu Industrijsko inženjerstvo i modulu Poslovni informacioni sistemi Fakulteta inženjerskih nauka Univerziteta u Kragujevcu završila je 2013. godine, sa prosečnom ocenom 9,63. Na ovom studijskom programu je diplomirala prva u generaciji i sa najvećom prosečnom ocenom. Godine 2013. upisala je studijski program doktorskih studija Elektrotehničkog i računarskog inženjerstva Fakulteta tehničkih nauka u Kosovskoj Mitrovici, na kojem je položila sve potrebne ispite sa prosečnom ocenom 10. Od 14. oktobra 2013. do 13. oktobra 2014. godine Milena Jevtić je radila kao saradnik u nastavi na Tehničkom fakultetu u Boru. Na istom Fakultetu, od 25. septembra 2014. godine do danas ona obavlja poslove asistenta, tj. drži numeričke i softversko-aplikativne vežbe iz grupe predmeta iz oblasti Računarstva i informatike. Učestvuje na nacionalnom naučno-istraživačkom projektu finansiranom od strane Vlade Republike Srbije: „Razvoj modela male hidroelektrane za izolovano napajanje ribnjaka i mikro mreže sa različitim obnovljivim izvorima energije“ (TR 33046). Oblasti interesovanja Milene Jevtić su: Veštačka inteligencija, Računarska inteligencija, Soft Computing i Računarstvo u obradi informacija. Autor i koautor je većeg broja radova u časopisima i na konferencijama nacionalnog i međunarodnog značaja. Održava i ažurira sledeća dva sajta Tehničkog fakulteta u Boru: <http://menadzment.tfbor.bg.ac.rs/> i <http://emfm.tfbor.bg.ac.rs/>. Urednik je studentskog časopisa međunarodnog značaja “Engineering Management“ ISSN online 2466 – 2860 i koautor je jednog pomoćnog udžbenika. Član je Organizacionog odbora međunarodne konferencije “International Symposium on Environmental and Material Flow Management - EMFM“ koji se održava svake godine.

Izjava o autorstvu

Potpisana: Milena Jevtić

Broj indeksa: 1/2013

Izjavljujem

da je doktorska disertacija pod nazivom

“Adaptivna optimizacija inspirisana vetrom i Algoritam noćnih leptira u rešavanju problema raspodele snaga generatora“

- rezultat sopstvenog istraživačkog rada,
- da predložena disertacija u celini ni u delovima nije bila predložena za dobijanje bilo koje diplome prema studijskim programima drugih visokoškolskih ustanova,
- da su rezultati korektno navedeni i
- da nisam kršila autorska prava i koristila intelektualnu svojinu drugih lica.

Potpis doktoranda

U Kosovskoj Mitrovici,

Izjava o istovetnosti štampane i elektronske verzije doktorskog rada

Ime i prezime autora: Milena Jevtić

Broj indeksa: 1/2013

Studijski program: Elektrotehničko i računarsko inženjerstvo

Naslov rada: “Adaptivna optimizacija inspirisana vetrom i algoritam noćnih leptira u rešavanju problema ekonomične raspodele snaga generatora”

Mentor: dr. Nenad Jovanović, vanredni profesor

Potpisani: Milena Jevtić

Izjavljujem da je štampana verzija mog doktorskog rada istovetna elektronskoj verziji koju sam predala za objavljivanje na portalu Digitalnog repozitorijuma Univerziteta u Prištini, sa privremenim sedištem u Kosovskoj Mitrovici.

Dozvoljavam da se objave moji lični podaci vezani za dobijanje akademskog zvanja doktora nauka, kao što su ime i prezime, godina i mesto rođenja i datum odbrane rada.

Ovi lični podaci mogu se objaviti na mrežnim stranicama digitalne biblioteke, u elektronskom katalogu i u publikacijama Univerziteta u Prištini, sa privremenim sedištem u Kosovskoj Mitrovici.

У Косовској Митровици,

Potpis doktoranda

Izjava o korišćenju

Ovlašćujem Univerzitetsku biblioteku da u Digitalni repozitorijum Univerziteta u Prištini, sa privremenim sedištem u Kosovskoj Mitrovici i Nacionalni repozitorijum doktorskih disertacija unese moju doktorsku disertaciju pod naslovom:

“Adaptivna optimizacija inspirisana vetrom i algoritam noćnih leptira u rešavanju problema ekonomične raspodele snaga generatora“

koja je moje autorsko delo.

Disertaciju sa svim prilogima predala sam u elektronskom formatu pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju pohranjenu u Digitalni repozitorijum Univerziteta u Prištini sa privremenim sedištem u Kosovskoj Mitrovici i Nacionalni repozitorijum doktorskih disertacija mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (Creative Commons) za koju sam se odlučila.

1. Autorstvo
2. Autorstvo - nekomercijalno
3. Autorstvo – nekomercijalno – bez prerade

4. Autorstvo – nekomercijalno – deliti pod istim uslovima

5. Autorstvo – bez prerade
6. Autorstvo – deliti pod istim uslovima

(Molimo da zaokružite samo jednu od šest ponuđenih licenci, kratak opis licenci dat je na poledini lista).

U Kosovskoj Mitrovici,

Potpis doktoranda

1. Autorstvo – Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence, čak i u komercijalne svrhe. Ovo je najslobodnija od svih licenci.
2. Autorstvo – nekomercijalno. Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu upotrebu dela.
3. Autorstvo – nekomercijalno – bez prerade. Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu upotrebu dela. U odnosu na sve ostale licence, ovom licencom se ograničava najveći obim prava korišćenja dela.
4. Autorstvo – nekomercijalno – deliti pod istim uslovima. Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca ne dozvoljava komercijalnu upotrebu dela i prerada.
5. Autorstvo – bez prerade. Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca dozvoljava komercijalnu upotrebu dela.
6. Autorstvo – deliti pod istim uslovima. Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca dozvoljava komercijalnu upotrebu dela i prerada. Slična je softverskim licencama, odnosno licencama otvorenog koda.