

**UNIVERZA V MARIBORU**  
FAKULTETA ZA ELEKTROTEHNIKO,  
RAČUNALNIŠTVO IN INFORMATIKO

Adnan GLOTIĆ

**Optimiranje elementov elektroenergetskega omrežja  
z uporabo evolucijskih algoritmov**

Doktorska disertacija

Maribor, april 2011

Avtor: Adnan GLOTIĆ, univ. dipl. inž. el.

Naslov: Optimiranje elementov elektroenergetskega omrežja z uporabo evolucijskih algoritmov

Naslov v angleščini: Optimization of electrical power network elements by using evolutionary algorithms

UDK: 621.315/.316(043.3)

Ključne besede: Diferenčna evolucija, elektroenergetsko omrežje, izolator, Kriging, optimizacija, stikalne naprave.

Število strani: 147

Obdelava slik in besedila: Adnan GLOTIĆ, univ. dipl. inž. el.

Razmnoževanje: Laboratorij za energetiko, UM FERl

Število izvodov: 11

Kraj in datum: Maribor, april 2011



Na osnovi 287., 140., 142. in 144. člena Statuta Univerze v Mariboru (Statut UM-UPB7, Ur. l. RS, št. 36/2009) ter sklepa 28. redne seje Senata Univerze v Mariboru z dne 29. 1. 2010 v zvezi z vlogo doktorskega kandidata Adnana Glotića za sprejem odločitve o predlagani temi doktorske disertacije in mentorja,

izdajam naslednji

### SKLEP

**Odobri se tema doktorske disertacije Adnana Glotića s Fakultete za elektrotehniko, računalništvo in informatiko z naslovom »Optimiranje elementov elektroenergetskega omrežja z uporabo evolucijskih algoritmov«. Kandidatu se za mentorja imenuje red. prof. dr. Jože Pihler, za somentorja pa red. prof. dr. Igor Tičar. Kandidat mora članici predložiti izdelano doktorsko disertacijo v zadostnih izvodih najpozneje do 28. 1. 2014.**

#### Obrazložitev:

Kandidat Adnan Glotić je dne 17. 8. 2009 na Fakulteti za elektrotehniko, računalništvo in informatiko vložil vlogo za potrditev teme doktorske disertacije z naslovom »Optimiranje elementov elektroenergetskega omrežja z uporabo evolucijskih algoritmov«. Za mentorja je bil predlagan red. prof. dr. Jože Pihler, za somentorja pa red. prof. dr. Igor Tičar.

Senat Fakultete za elektrotehniko, računalništvo in informatiko je na osnovi pozitivnega mnenja komisije za oceno teme doktorske disertacije, ki je ugotovila, da kandidat izpolnjuje pogoje za pridobitev doktorata znanosti, in ocenila, da je predlagana tema ustrezna, sprejel pozitivno mnenje in poslal predlog teme doktorske disertacije s predlogom mentorja in somentorja v odobritev Senatu univerze.

Senat Univerze v Mariboru je po proučitvi vloge in na osnovi določil Statuta Univerze v Mariboru sprejel svojo odločitev o predlagani temi doktorske disertacije in imenoval mentorja in somentorja, kot izhaja iz izreka.

V skladu s 144. členom Statuta Univerze v Mariboru mora kandidat za pridobitev doktorata znanosti najpozneje v štirih letih od dneva izdaje tega sklepa, članici

predložiti izdelano doktorsko disertacijo v zadostnih izvodih. Kandidatu je bil določen rok glede na datum sprejetja teme na pristojnem organu.

**Pouk o pravnem sredstvu:**

Zoper ta sklep je možna pritožba na Senat Univerze v Mariboru v roku 8 dni od prejema tega sklepa.



Rektor:  
Prof. dr. Ivan Rozman

Obvestiti:

1. Kandidata.
2. Fakulteto.
3. Arhiv.



**Univerza v Mariboru**

*Fakulteta za elektrotehniko,  
računalništvo in informatiko*

Doktorska disertacija

# **Optimiranje elementov elektroenergetskega omrežja z uporabo evolucijskih algoritmov**

Maribor, april 2011

Avtor: Adnan GLOTIĆ  
Mentor: red. prof. dr. Jože PIHLER  
Somentor: red. prof. dr. Igor TIČAR  
Lektor: Bojana VRBNJAK, prof.  
UDK: 621.315/.316(043.3)

## *Zahvala*

Za nasvete in strokovno vodenje pri izdelavi doktorske disertacije se zahvaljujem mentorju, red. prof. dr. Jožetu Pihlerju, in somentorju, red. prof. dr. Igorju Tičarju. Prav tako se zahvaljujem izr. prof. dr. Nerminu Sarajliću kot tudi izr. prof. dr. Janezu Brestu ter doc. dr. Petru Kitaku za vso pomoč in praktične nasvete.

Posebej se zahvaljujem tudi svojim družinskim članom, ki so me podpirali in spodbujali pri mojem delu.

# Optimiranje elementov elektroenergetskega omrežja z uporabo evolucijskih algoritmov

**Ključne besede:** Diferenčna evolucija, elektroenergetske omrežje, izolator, Kriging, optimizacija, stikalne naprave.

**UDK:** 621.315/.316(043.3)

## *Povzetek*

V okviru doktorske disertacije je narejen pregled stanja na področju optimizacij in ugotavljanje učinkovitosti nekaterih optimizacijskih metod v domeni reševanja realnih tehniških problemov. Lastne izkušnje kot tudi pregled objav na obravnavanem področju so pokazale, da je kot optimizacijski algoritem za podrobnejšo obravnavo in reševanje optimizacijskih problemov elementov elektroenergetskega omrežja, algoritem diferenčne evolucije zelo primeren.

Odprtost, prilagodljivost in preprostost samega algoritma diferenčne evolucije je med drugim omogočila njegovo enostavno integracijo v algoritem za načrtovanje in identifikacijo parametrov, ki ga lahko uporabljamo za reševanje tako direktnih kot inverznih problemov. Dodatna nadgradnja algoritma omogoča tudi izvajanje parametrične analize, kot je prikazano na enem izmed predstavljenih optimizacijskih problemov.

Slaba lastnost algoritma diferenčne evolucije, ki je sorodna vsem evolucijskim algoritmom, je zahtevano veliko število cenitev kriterijske funkcije za doseganje konvergence optimizacijskega postopka. Izboljšanje omenjene slabosti je bilo v okviru disertacije realizirano z razširitvijo izvirnega algoritma oz. z njegovo dopolnitvijo s Kriging interpolacijsko metodo. Preskusi na različnih standardnih testnih funkcijah kot tudi na realnem inženirskem problemu so pokazali, da potrebuje novi algoritem v primerjavi z izvirnim povprečno pol manj cenitev dejanske kriterijske funkcije, da doseže globalni optimum, in to s popolnoma enako natančnostjo. Pri reševanju realnih tehniških optimizacijskih problemov to pomeni prihranek časa v približno enakem obsegu.

V okviru disertacije so prikazane tudi podrobnosti aplikacij algoritmov in rezultati optimizacije za primere različnih naprav, kot so transformator, plinski odvodnik, skožnjik, podporni kompozitni izolator, kot tudi za primer konfiguracije omrežja.

# Optimization of electrical power network elements by using evolutionary algorithms

**Keywords:** Differential evolution, Electric power network, Insulator, Kriging, Optimization, Switchgear.

**UDC:** 621.315/.316(043.3)

## *Summary*

In the presented work, the overview in the field of real-world optimizations has been made as well as the established efficiency of individual optimization techniques. Based on experiences and published results, it has been concluded that one of the appropriate optimization algorithms, for solving optimization problems of electric power network devices and elements, is Differential evolution algorithm.

Openness, adjustability and its simplicity enable integration of the Differential evolution algorithm into the algorithm for designing and parameter identification. In this context, the algorithm is able to solve direct as well as the inverse problems. Additional upgrade of the algorithm enables a parametrical analysis that has been carried out on one among presented optimization problems.

Downside of the Differential evolution is the required large number of function evaluations, in order to approach the global solution. This is also common to practically all Evolutionary algorithms. To improve this property of Differential evolution algorithm, one has been extended to use Kriging interpolation method. Newly developed Kriging-assisted differential evolution algorithm enables the reduction of required function calls. Experiments which have been conducted on several standard test functions, and also on a real engineering problem, have shown that new algorithm, compared to original Differential evolution algorithm, generally reduces a number of actual function calls by half. The reduction of the time needed to finish the optimization process, respectively to achieve the convergence, is about the same and is decreased by half. It should be pointed out that the precision of solutions, obtained with new algorithm, is equal, as in the case of the original Differential evolution algorithm.

Applications of optimization algorithms have been demonstrated on different elements of electric power network, i.e. transformer, gas discharge arrester, bushing and the post composite insulator.



# Vsebina

<b>1. Uvod</b>	<b>1</b>
<b>2. Optimizacija</b>	<b>7</b>
2.1 Matematično ozadje	8
2.1.1 Minimum	9
2.1.2 Lokalni in globalni minimum	9
2.1.3 Gradient, Hessianova matrika, Taylorjeva vrsta	10
2.1.4 Eno- in večmodalne kriterijske funkcije	11
2.1.5 Omejeni in neomejeni optimizacijski problemi	13
2.2 Delitev optimizacijskih metod	13
2.2.1 Predstavitev nekaterih determinističnih optimizacijskih metod	14
2.2.1.1 Metoda strmega spusta	14
2.2.1.2 Metoda konjugiranih gradientov	15
2.2.1.3 Newtonova metoda	17
2.2.1.4 Primerjava predstavljenih determinističnih metod na analitično zapisanih funkcijah	19
2.2.2 Predstavitev nekaterih stohastičnih optimizacijskih metod	20
2.2.2.1 Genetski algoritem	22
2.2.2.2 Evolucijska strategija	26
2.2.2.3 Diferenčna evolucija	27
2.2.2.4 Primerjava predstavljenih stohastičnih metod na analitično zapisanih funkcijah	32
<b>3. Razširitve algoritma diferenčne evolucije</b>	<b>37</b>
3.1 Večkriterijska optimizacija	38
3.1.1 Pareto dominantnost	40
3.1.2 Pareto optimalnost	41
3.1.3 Pareto fronta	41
3.2 Algoritem diferenčne evolucije za večkriterijsko optimizacijo (DEMO)	42
3.2.1 Elementi redukcije velikosti in vzdrževanja raznolikosti populacije	44
3.2.1.1 Nedominirano sortiranje (Pareto rangiranje)	44
3.2.1.2 Metrika nakopičenosti	44
3.2.1.3 Klestenje populacije	46
3.2.2 Predstavitev delovanja algoritma DEMO na preprostem zgledu	47
3.3 Interpolacijska Kriging metoda	49
3.3.1 Uvod	49
3.3.2 Kriging	50

3.3.3	Predstavitev delovanja Kriging metode .....	52
3.4	Algoritem diferenčne evolucije s Kriging podporo - KADE .....	54
3.4.1	Primerjava algoritmov DE in KADE na analitično zapisanih testnih funkcijah .....	58
3.4.2	Vpliv krmilnih parametrov na učinkovitost algoritma KADE.....	60
<b>4.</b>	<b>Teoretične osnove za numerične izračune .....</b>	<b>63</b>
4.1	Teoretične osnove za obravnavo nekaterih elementov stikalnih naprav .....	63
4.1.1	Elektrostatično polje.....	65
4.1.2	Električni skalarni potencial.....	68
4.1.3	Zapis elektrostatičnega polja z Galerkinovim postopkom.....	69
4.1.4	Metoda končnih elementov.....	71
4.2	Teoretične osnove za obravnavo energetskega transformatorja.....	74
4.2.1	Matematični model izračuna dvodimenzionalnih elektromagnetnih polj.....	74
4.2.2	Matematični model izračuna dvodimenzionalnih temperaturnih polj .....	77
4.2.3	Medsebojni vpliv elektromagnetnega in temperaturnega polja .....	79
4.2.3.1	Direktni vpliv preko temperaturno odvisnih karakteristik materialov.....	79
4.2.3.2	Direktni vpliv na izračun Joulovih izgub .....	79
4.2.3.3	Reševanje sklopljenega elektromagnetno-temperaturnega problema.....	80
4.3	Teoretične osnove za obravnavo plinskega odvodnika.....	81
4.3.1	Matematični model plinskega odvodnika.....	82
4.3.1.1	Faza pred razelektivitvijo.....	82
4.3.1.2	Faza razelektivitve.....	83
4.3.1.3	Faza gorenja obloka.....	84
4.3.1.4	Prehod iz obloka v samostojno razelektrenje s prostorskim nabojem .....	85
4.3.1.5	Faza samostojne razelektivitve s prostorskim nabojem.....	85
<b>5.</b>	<b>Aplikacija optimizacijskih algoritmov na različnih elementih elektroenergetskega omrežja in rezultati.....</b>	<b>87</b>
5.1	Optimizacija geometrije podpornega kompozitnega izolatorja z uporabo diferenčne evolucije in genetskega algoritma .....	87
5.1.1	Uvod .....	87
5.1.2	Predstavitev objekta .....	88
5.1.3	Analiza električnega polja z uporabo orodja EleFAnT2D.....	89
5.1.4	Kriterijska funkcija .....	90
5.1.5	Algoritem za načrtovanje.....	92
5.1.6	Rezultati optimizacije.....	92
5.2	Izboljšanje natančnosti termičnega MKE modela transformatorja z uporabo optimizacije.....	95

5.2.1	Uvod.....	95
5.2.2	Predstavitev matematičnega modela .....	95
5.2.3	Kriterijska funkcija .....	96
5.2.4	Postopek določanja parametrov termičnega MKE modela transformatorja .....	98
5.2.5	Rezultati optimizacije .....	101
5.3	Določitev parametrov modela plinskega odvodnika s pomočjo meritev in optimizacije .....	104
5.3.1	Uvod.....	104
5.3.2	Predstavitev objekta .....	104
5.3.3	Predstavitev matematičnega modela .....	105
5.3.4	Kriterijska funkcija .....	106
5.3.5	Meritve .....	106
5.3.6	Primerjava rezultatov meritev in simulacij .....	107
5.3.7	Rezultati optimizacije .....	109
5.4	Večkriterijsko optimiranje konfiguracije omrežja v povezavi s stroški in zanesljivostjo.....	115
5.4.1	Uvod.....	115
5.4.2	Predstavitev kriterijskih funkcij .....	115
5.4.3	Rezultati optimizacije.....	119
5.5	Optimizacija skoznjika z uporabo algoritmov DE in KADE.....	121
5.5.1	Predstavitev problema.....	121
5.5.2	Analiza problema in definiranje kriterijske funkcije.....	121
5.5.3	Rezultati optimizacije .....	124
<b>6.</b>	<b>Sklep.....</b>	<b>125</b>
	<b>LITERATURA .....</b>	<b>127</b>
	<b>OSEBNA BIBLIOGRAFIJA .....</b>	<b>137</b>
	<b>PRILOGA.....</b>	<b>143</b>
	<b>ŽIVLJENJEPIS .....</b>	<b>149</b>



## Kazalo slik

2.1:	Predstavitev a) minimuma, b) maksimuma in c) sedla funkcije .....	10
2.2:	Predstavitev a) zvezne b) nezvezne c) omejene in d) diskretne funkcije .....	12
2.3:	Pregled oblike nekaterih KF .....	12
2.4:	Testni 2D funkciji .....	19
2.5:	Konture grafa funkcije s slike 2.4 a in trajektorije približevanja k minimumu za a) metodo strmega spusta, b) metodo konjugiranih gradientov in c) Newtonovo metodo .....	19
2.6:	Konture grafa funkcije s slike 2.4 b in trajektorija približevanja k minimumu za a) metodo strmega spusta, b) metodo konjugiranih gradientov in c) Newtonovo metodo .....	20
2.7:	Selekcija z ruleto .....	23
2.8:	Križanje z eno točko .....	24
2.9:	Križanje z dvema točkama .....	24
2.10:	Primer uniformnega križanja .....	24
2.11:	Grafični prikaz diferenčne mutacije v prostoru dveh spremenljivk .....	30
2.12:	Križanje vmesnega (mutiranega) $\mathbf{v}_{i,g}$ in baznega vektorja $\mathbf{x}_{i,g}$ v postopku generiranja začasnega vektorja $\mathbf{u}_{i,g}$ .....	31
2.13:	Elitistična selekcija .....	32
2.14:	Shema delovanja DE algoritma .....	32
2.15:	Testni funkciji: a) <i>Rastrigin</i> in b) <i>Rosenbrock</i> .....	33
2.16:	Rezultati za posamezne algoritme – a) GA, b) DE in c) ES za <i>Rastrigin</i> (levo) ter d) GA, e) DE in f) ES za testno funkcijo <i>Rosenbrock</i> (desno) .....	34
3.1:	Prikaz koncepta dominantnosti na primeru večkriterijske funkcije $f$ .....	39
3.2:	Cilja večkriterijske optimizacije .....	40
3.3:	Dominirane in nedominirane rešitve v prostoru dveh kriterijev .....	41
3.4:	Pareto optimalna fronta .....	42
3.5:	Algoritem DEMO in generiranje kandidata za rešitev po shemi DE/rand/1/bin .....	43
3.6:	Proces rangiranja pri pristopu nedominiranega sortiranja .....	44
3.7:	Računanje metrike nakopičenosti .....	45
3.8:	Pareto optimalna množica, kjer sta označeni rešitvi z večjo (rdeča) in manjšo (modra) metriko nakopičenosti .....	45
3.9:	Primer Pareto optimalne množice z razporeditvijo osebkov, pri kateri je informacija o nakopičenosti zavajajoča .....	46
3.10:	Klestenje populacije v algoritmu DEMO .....	47
3.11:	Kondenzator kot večkriterijski optimizacijski problem .....	47
3.12:	a) Razširjena populacija staršev in potomcev b) Nedominirano sortiranje oz. Pareto rangiranje .....	48
3.13:	Prikaz Pareto optimalne fronte .....	48
3.14:	a) Graf dejanske 2D <i>Ackley</i> funkcije b) Izris odziva metamodela (točke) .....	52
3.15:	Primerjava originalne in aproksimirane funkcije pri različnih gostotah izrisa .....	53
3.16:	Grafična predstavitev algoritma KADE .....	57

3.17:	Testne funkcije a) <i>Ackley</i> b) <i>Michalewicz</i> in c) <i>Schwefel</i> .....	59
3.18:	Uspešnost algoritmov DE in KADE v odvisnosti od $F$ in $Cr$ .....	61
3.19:	Število cenitev dejanske KF v odvisnosti od $F$ in $Cr$ .....	62
3.20:	Prihranek cenitev dejanske KF pri algoritmu KADE glede na DE.....	62
4.1:	Predstavitev elektrostatičnega problema .....	66
4.2:	Osemvozliščni kvadratni element v lokalnem in globalnem koordinatnem sistemu .....	72
4.3:	Oblikovne funkcije elementa z osemvozliščnim kvadratnim elementom.....	73
4.4:	Faze delovanja modela PO.....	82
5.1:	a) Fotografija PKI b) Sestavni deli PKI in predstavitev parametrov za optimizacijo geometrije.....	88
5.2:	a) Diskretizirano področje izolatorja z okolico b) Električno polje, izračunano pri preskusni napetosti 125 kV.....	89
5.3:	Pridruženi zvončasti funkciji: a) kriterij najboljšega ujemanja b) kriterij <i>minimum</i> .....	91
5.4:	Oblika KF za optimizacijo geometrije PKI .....	91
5.5:	Grafični prikaz algoritma za načrtovanje in optimizacijo .....	92
5.6:	Najboljša, najslabša in povprečna vrednost KF v posamezni generaciji za a) DE in b) GA .....	93
5.7:	Sprememba vrednosti KF najboljšega osebka za a) DE in b) GA.....	94
5.8:	Trajektorije najboljšega osebka za a) DE in b) GA.....	94
5.9:	Fotografija merjenca - trifazni 2.4 kVA transformator.....	95
5.10:	Predstavitev povezave med izrazoma ABEOS in AUES ter NRMS normo .....	97
5.11:	Grafična predstavitev algoritma za določitev parametrov .....	98
5.12:	Vsebina datoteke <i>resgen.bat</i> .....	99
5.13:	Del vsebine datoteke <i>expgen.bat</i> .....	99
5.14:	Univerzalni algoritem za načrtovanje in identifikacijo parametrov.....	100
5.15:	a) Izmerjena in izračunana temp. (nazivna obremenitev) b) Absolutna napaka izračuna pri nazivni obremenitvi .....	102
5.16:	a) Prikaz konvergence optimizacijskega postopka b) Trajektorije najboljšega osebka skozi celo evolucijo .....	103
5.17:	Izračunana in izmerjena temperatura pri 2/3 nazivne obremenitve.....	103
5.18:	a) Zgradba PO b) Fotografija vzorca c) Notranjost odsluženega PO .....	104
5.19:	Model PO vključen v merilno progo .....	107
5.20:	Signal napetosti in toka izmerjen pri delovanju PO.....	107
5.21:	Primerjava izmerjenih in izračunanih a) napetosti in b) tokov.....	108
5.22:	Algoritem za identifikacijo parametrov in parametrično analizo .....	109
5.23:	Vzorec št. 1, meritev št. 2 – a) trajektorije parametrov najboljšega in b) najslabšega osebka, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji .....	110
5.24:	Sprememba vrednosti KF skozi evolucijo za najboljši osebek.....	111
5.25:	Izmerjeni in s pomočjo optimalnih parametrov izračunani signali za a) napetost in b) tok.....	111
5.26:	Vzorec št. 1, meritev št. 1 – a) trajektorije parametrov najboljšega in b) najslabšega osebka, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji .....	112

5.27:	Vzorec št. 1, meritev št. 3 – a) trajektorije parametrov najboljšega in b) najslabšega osebk, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji .....	112
5.28:	Vzorec št. 1, meritev št. 4 – a) trajektorije parametrov najboljšega in b) najslabšega osebk, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji .....	113
5.29:	Spremembe parametrov modela v odvisnosti od števila delovanj vzorca št. 1.....	114
5.30:	Stroški zaradi a) načrtovanih in b) nenačrtovanih prekinitev in trajanja prekinitev v odvisnosti od stopnje vzankanja in pokablitve ter časa popravila.....	117
5.31:	a) Stroški vzdrževanja b) Investicijska vlaganja.....	117
5.32:	Sistemska kazalca za nenačrtovane prekinitve v odvisnosti od stopnje vzankanja in pokablitve ter časa popravila - a) SAIFI in b) SAIDI.....	118
5.33:	Sistemska kazalca za načrtovane prekinitve v odvisnosti od stopnje vzankanja in pokablitve - a) SAIFI in b) SAIDI.....	118
5.34:	Kriterijski funkciji – a) skupni stroški $C$ ter b) kakovost $Q$ v odvisnosti od stopnje vzankanja, stopnje pokablitve in časa popravila.....	119
5.35:	Rezultat optimizacije z uporabo DEMO algoritma – a) prikaz vseh rešitev v prostoru kriterijev dobljenih skozi celotno evolucijo in b) prikaz zadnje ter predzadnje populacije (Pareto fronta).....	120
5.36:	Fotografija različnih vrst skoznjikov .....	121
5.37:	a) Diskretizirani model skoznjika b) Izris električnega polja.....	122
5.38:	Kriterijska funkcija za: a) električno poljsko jakost in b) razmerje poljskih jakosti v dveh dielektrikih .....	123
5.39:	Oblika KF ( $p_1, p_4$ na sliki a ter $p_1, p_2$ na sliki b so fiksirani) .....	123





## Kazalo tabel

2.1:	Primerjava algoritmov za a) Rastrigin in b) Rosenbrock funkcijo .....	35
3.1:	Seznam testnih funkcij .....	58
3.2:	Rezultati optimizacije testnih funkcij z algoritmoma DE in KADE .....	60
5.1:	Rezultati optimizacije geometrije PKI .....	93
5.2:	Termični parametri – mejne in identificirane/optimalne vrednosti.....	101
5.3:	Meje optimizacijskih parametrov in optimalne vrednosti .....	110
5.4:	Optimalne vrednosti parametrov določenih za vzorec PO št. 1.....	113
5.5:	Ocena ujemanja izmerjenih in izračunanih signalov (vrednost KF).....	114
5.6:	Rezultati optimizacije skoznjika z uporabo algoritmov DE in KADE .....	124
A. 1:	Rezultati optimizacije konfiguracije omrežja v povezavi z zanesljivostjo in stroški .....	143



## Uporabljene kratice

ABEOS	Površina med izmerjeno in izračunano krivuljo (angl. <i>Area Between the Exact and the Obtained Solution</i> )
AUES	Površina pod izmerjeno krivuljo (angl. <i>Area Under the Exact Solution</i> )
DE	Diferenčna evolucija
EA	Evolucijski algoritmi
EEO	Elektroenergetsko omrežje
ES	Evolucijska strategija
GA	Genetski algoritem
I/O	Vhod/Izhod (angl. <i>Input/Output</i> )
ICEM-TC	Infrastrukturni center za elektroenergetske meritve – Tehnološki center
KADE	Diferenčna evolucija s podporo Kriging interpolacijske metode (angl. <i>Kriging-assisted Differential Evolution</i> )
KE	Končni element
KF	Kriterijska funkcija
MKE	Metoda končnih elementov
NPMC	Število točk za gradnjo metamodela (angl. <i>Number of Points for Metamodel Construction</i> )
NRMS	Normirana efektivna vrednost
NS	Število uspešnih zagonov algoritma (angl. <i>Number of Success</i> )
PDE	Parcialna diferencialna enačba
PKI	Podporni kompozitni izolator
PO	Plinski odvodnik
PPI	Priviligirani indeksi populacije (angl. <i>Privileged Population Index</i> )
RMS	Efektivna vrednost (angl. <i>Root Mean Square</i> )
SAIDI	Indeks povprečne frekvence prekinitev v sistemu
SAIFI	Indeks povprečnega trajanja prekinitev v sistemu
VTR	Zaustavitveni kriterij optimizacije (angl. <i>Value-To-Reach</i> )
UV	Ultravijolično valovanje



## Uporabljeni simboli in oznake

<b>A</b>	Magnetni vektorski potencial [Vs/m]; Poljubna vektorska funkcija
<b>A</b>	Poljubna pozitivno definitna in simetrična matrika
$a, b$	Interpolacijska koeficienta [ $s^2/V$ ]; Vrednosti, ki označujeta meje osebka v prostoru parametrov
<b>B</b>	Gostota magnetnega pretoka [Vs/m <sup>2</sup> ]
$b_v$	Utež pri vmesnem križanju (ES)
<b>C</b>	Skupni stroški [€]
$c$	Specifična toplotna kapacitivnost [J/kgK]
$c_i$	Vrednosti skalarnih funkcij, ki določajo omejitve spreminjanja optimizacijskih parametrov
$Cr$	Verjetnost križanja (DE)
$c_x$	Mera nakopičenosti opazovanega osebka
$d$	Razdalja med elektrodama [m]; Koeficienti vektorja sistema
<b>D</b>	Dimenzija optimizacijskega problema; Število optimizacijskih parametrov
<b>D</b>	Gostota električnega pretoka [As/m <sup>2</sup> ]
<b>d</b>	Poljubni vektor; Vektor sistema
<b>E</b>	Električna poljska jakost [V/m]
<b>e</b>	Napaka; Vektor razlik med izmerjenimi in izračunanimi vrednostmi
$f$	Funkcija; Kriterijska funkcija
$F$	Utež oz. skalirni faktor v postopku mutacije (DE)
<b>f</b>	Vektor kriterijskih funkcij oz. večkriterijska funkcija
$f_{best}$	Najboljša vrednost kriterijske funkcije
$f_{ref.}$	Referenčna vrednost kriterijske funkcije
<b>g</b>	Odvod kriterijske funkcije oz. gradient v dani točki
$g$	Število, ki označuje generacijo v optimizacijskem algoritmu; Prevodnost [S]
$g_{max}$	Maksimalno dovoljeno število generacij v optimizacijskem algoritmu
<b>H</b>	Hessianova matrika
$h$	Interpolacijska funkcija; Velikost koraka za premik v novo točko pri determinističnih optimizacijskih metodah
<b>H</b>	Vektor magnetne poljske jakosti [A/m]
$i$	Trenutna vrednost toka [A]; Števec; Število, ki označuje položaj v danem zaporedju: $i$ -ti vektor, $i$ -ti element
<b>I</b>	Enotska matrika
$I_{ex}$	Tok ugasnitve obloka [A]
$i_{izm}$	Izmerjene vrednosti toka [A]
$i_{sim}$	Izračunane vrednosti toka [A]
$j$	Števec; Število, ki označuje položaj v danem zaporedju: $j$ -ti vektor, $j$ -ti element
<b>J</b>	Tokovna gostota [A/m <sup>2</sup> ]
$J_i$	Vektor gostote električnega toka zunanjih izvorov [A/m <sup>2</sup> ]
$k$	Števec; Število, ki označuje položaj v danem zaporedju: $k$ -ti vektor, $k$ -ti element
<b>K<sub>m</sub></b>	Površinska magnetna tokovna gostota [V/m]
$k_T$	Empirična <i>Toeplerjeva</i> konstanta [Vs/m]

$k_{\text{Tag}}$	Toeplerjeva konstanta pri ponovni razelektritvi, ko je oblok že ugasnil in pride do ponovne razelektritve [Vs/m]
$l$	Število genov v kromosomu
$l, d$	Konstanti pridružene zvončaste funkcije
$\mathbf{M}$	Vektor magnetne polarizacije [A/m]
$m$	Vrednost, pri kateri pridružena zvončasta funkcija zasede vrednost 1; Število enakosti oz. neenakosti v domeni omejitev prostora parametrov
$m_{p_i}$	Izmerjene vrednosti temperature v izbrani točki, zmanjšane za temperaturo ambianta [K]
$m_s$	Spodnja meja optimizacijskih parametrov
$m_z$	Zgornja meja optimizacijskih parametrov
$\mathbf{n}$	Normala na obravnavano površino
$n$	Števec
$n_E$	Število Dirichletovih področij
$n_{\text{feval}}$	Število cenitev kriterijske funkcije
$n_i$	Števec dominacij
$N_k$	Oblikovna funkcija končnega elementa
$NP$	Velikost populacije (DE)
$p$	Optimizacijski parameter; Spremenljivka
$\mathbf{P}$	Vektor električne polarizacije [As/m <sup>2</sup> ]
$P_0$	Mayerjeva konstantna moč - izgube obloka [W]
$P_i$	Opazovana oz. $i$ -ta točka; $i$ -ta merilna točka
$\mathbf{P}_u$	Začasna populacija – populacija potomcev (DE)
$\mathbf{P}_v$	Vmesna populacije – populacija mutiranih osebkov (DE)
$\mathbf{P}_x$	Trenutna populacija – populacija staršev (DE)
$Q$	Električni naboj [As]; Kakovost [p.u.]
$q$	Vrednost kriterijske funkcije
$q_p$	Količina toplote, ki prehaja površino trdega telesa [W/m <sup>2</sup> ]
$R$	Korelacijska funkcija; Residuum
$\mathbf{R}$	Korelacijska matrika
$R$	Odstotek znižanja števila klicev dejanske kriterijske funkcije (KADE) [%]
$\mathbf{R}$	Poljubna vektorska funkcija
$\mathbf{r}$	Vektor korelacijske funkcije
$\mathbf{r}, \mathbf{r}'$	Vektor položaja
rand	Naključno generirana vrednost
$R_g$	Stacionarna vrednost upornosti v fazi razelektritve s prostorskim nabojem [ $\Omega$ ]
$R_{ga}$	Mejna upornost med fazo razelektritve in obloka [ $\Omega$ ]
$r_{kb}$	Razmerje med dolžino podzemnih vodov in dolžino vseh vodov
$R_s$	Spremenljiva upornost [ $\Omega$ ]
$R_{s0}$	Upornost odprtega stikala [ $\Omega$ ]
$R_{s1}$	Upornost zaprtega stikala [ $\Omega$ ]
$R_{s10}$	Maksimalna upornost pri izklopu stikala [ $\Omega$ ]
$R_{\text{var}}$	Spremenljiva upornost [ $\Omega$ ]
$r_{vz}$	Razmerje med dolžino vzankanih vodov in dolžino vseh vodov
$\mathbf{S}$	Matrika sistema

$\mathbf{s}$	Smerni vektor pri gradientnih optimizacijskih metodah
$S$	Strmina naraščanja napetosti [V/s]; Stroški zaradi prekinitev in trajanja prekinitev [€]; Podmnožica realnih števil;
$SAIDI$	Indeks povprečnega trajanja prekinitev napajanja v sistemu [s]
$SAIFI$	Indeks povprečne frekvence prekinitev napajanja v sistemu
$S_{dv}$	Stroški vzdrževanja nadzemnih vodov [€]
$S_{kv}$	Stroški vzdrževanja kablovodov [€]
$S_{Na}$	Stroški načrtovanih prekinitev in trajanja prekinitev [€]
$S_{Ne}$	Stroški nenačrtovanih prekinitev in trajanja prekinitev [€]
$st.$	Strategija algoritma (DE)
$S_v$	Stroški vzdrževanja [€]
$t$	Čas [s]
$T$	Temperatura [K]
$T_c$	Izračunane vrednosti temperature [K]
$t_d$	Statistična zakasnitev razelektritve [s]
$t_{DC}$	Trenutek v katerem dosežemo vžigno napetost $U_{DC}$ [s]
$t_{ex}$	Trenutek prehoda med fazo gorenja obloka in fazo samostojne razelektritve s prostorskim nabojem [s]
$T_f$	Temperatura medija [K]
$T_m$	Izmerjene vrednosti temperature [K]
$T_o$	Temperatura okolice [K]
$T_p$	Temperatura površine telesa [K]
$t_r$	Čas sanacije okvare [s]
$U$	Električna napetost [V]
$\mathbf{u}$	Enotski vektor
$u$	Skalarna funkcija, ki predstavlja nabor možnih rešitev v okolici lokalnega optimuma
$U_{arc}$	Napetost obloka [V]
$U_{DC}$	Prebojna oz. vžigna napetost odvodnika [V]
$U_{DYN}$	Dinamična napetost razelektritve [V]
$\mathbf{u}_{i,g}$	$i$ -ti osebek populacije potomcev v generaciji $g$ (DE)
$\mathbf{u}_{izm}$	Izmerjene vrednosti napetosti [V]
$u_{j,i,g}$	$j$ -ti parameter $i$ -tega potomca v generaciji $g$ (DE)
$\mathbf{u}_{sim}$	Izračunane vrednosti napetosti [V]
$V$	Volumen [m <sup>3</sup> ]; Investicija (stroški) za zagotavljanje kakovosti [€]
$V_{dv}$	Cena daljnovoda [€]
$\mathbf{v}_{i,g}$	$i$ -ti osebek vmesne (mutirane) populacije v generaciji $g$ (DE)
$v_{j,i,g}$	$j$ -ti parameter $i$ -te vmesne rešitve v generaciji $g$ (DE)
$V_{kv}$	Cena kablovoda [€]
$W$	Električna energija [VAs]
$w$	Utež kriterijske funkcije [p.u.]; Utežna funkcija
$\mathbf{x}$	Vektor ali osebek – potencialna rešitev optimizacijskega problema
$\mathbf{x}^*$	Lokalni optimum
$\mathbf{x}_0$	Točka v prostoru parametrov (začetna točka)
$x_{d90\%}$	Vrednost desno od središča zvončaste funkcije, kjer je funkcijska vrednost 0,9

$x_i$	$i$ -ti parameter v vektorju
$\mathbf{x}_{i,g}$	$i$ -ti osebek v populaciji staršev v generaciji $g$ (DE)
$x_{j,i,g}$	$j$ -ti parameter $i$ -tega starša v generaciji $g$ (DE)
$x_{f90\%}$	Vrednost levo od središča zvončaste funkcije, kjer je funkcijska vrednost 0,9
$\mathbf{x}_p$	Potomec (ES)
$\mathbf{x}_{r1}$	Naključno izbrani starš v populaciji za izdelavo mutiranega osebk, kjer št. 1 označuje prvega od treh naključno izbranih staršev (DE).
$\mathbf{x}_s$	Starš (ES)
$y$	Odziv simulacijskega modela
$z$	Poljubna ali določena skalarna funkcija; Naključna funkcija



## Uporabljeni grški simboli in druge oznake

$\alpha$	Koeficient prehoda toplote [W/m <sup>2</sup> K]; Temperaturni koeficient specifične upornosti [K <sup>-1</sup> ]; Vrednost, ki minimizira dano funkcijo; Dolžina koraka (ES)
$\beta^*$	Regresijski parametri pri Kriging interpolacijski metodi
$\beta_k$	Faktor, ki definira smerni vektor pri metodi konjugiranih gradientov
$\delta$	Odmik optimizacijskih parametrov od lokalnega minimuma
$\psi$	Magnetni sklepi [Vs]
$\varepsilon$	Dielektričnost [As/Vm]; Emisivnost površine telesa
$\varepsilon_0$	Dielektričnost praznega prostora [As/Vm];
$\varepsilon_r$	Relativna dielektričnost oz. dielektrična konstanta
$\varphi$	Električni skalarni potencial [V]; Poljubna skalarna funkcija
$\mathfrak{F}$	Prostor dopustnih rešitev
$\Gamma$	Mejni rob
$\Gamma_D$	<i>Neumanov mejni rob</i>
$\Gamma_E$	<i>Dirichletov mejni rob</i>
$\lambda$	Koeficient prevajanja toplote [W/mK]; Potomci, nastali z rekombinacijo potomcev pri algoritmu ES
$\mu$	Permeabilnost [Vs/Am]; Velikost populacije staršev pri algoritmu ES
$\mu_0$	Permeabilnost praznega prostora [Vs/Am]
$\mu_r$	Relativna permeabilnost
$\mathfrak{M}$	Množica dopustnih rešitev
$\omega$	Krožna frekvenca [rad/s]
$\mathfrak{P}^*$	Pareto optimalna množica
$\mathfrak{P}\mathfrak{F}^*$	Pareto optimalna fronta
$\Pi$	Energijski funkcional
$\mathfrak{R}$	Množica realnih števil
$\mathfrak{R}^D$	<i>D</i> -dimenzijski prostor realnih števil
$\rho$	Električna gostota naboja [As/m <sup>3</sup> ], Specifična gostota [kg/m <sup>3</sup> ]; Specifična upornost [ $\Omega$ m]; Število staršev, nastalih z reprodukcijo (ES)
$\rho_s$	Električna gostota površinskega naboja [As/m <sup>2</sup> ]
$\sigma$	Električna prevodnost [S/m], Stefan-Boltzmannova konstanta [Wm <sup>-2</sup> K <sup>-4</sup> ];
$\sigma^2$	Varianca
$\tau$	Časovna konstanta, ki predstavlja razmerje med energijo v obloku in izgubami [s]
$\tau_1$	Časovna konstanta zapiranja stikala [s]
$\tau_2$	Časovna konstanta izklopa stikala [s]
$\tau_3$	Časovna konstanta ponovne sklenitve stikala [s]
$\tau_4$	Časovna konstanta naraščanja upornosti v prehodni fazi med ponovno razelektritvijo in razelektritvijo s prostorskim nabojem [s]
$\theta$	Korelacijski parameter
$\Omega$	Opazovano področje oz. domena
$\nabla$	Matematični operator <i>nabla</i>
$\xi, \eta, \zeta$	Lokalne koordinate globalnega koordinatnega sistema [m]



## 1. UVOD

Gradniki elektroenergetskega omrežja (EEO) oz. posamezni elementi imajo velik vpliv na zanesljivost delovanja EEO kot celote. V tem kontekstu so elementi EEO pridobili na svoji pomembnosti predvsem z vpeljavo prostega trga z električno energijo, ki je zaostрил razmere na področju prekinitev in motenj pri dobavi električne energije [1]. Zaradi tega je pomembno, da so elementi EEO skrbno načrtovani in zanesljivi pri svojem delovanju, saj je to osnovni pogoj za zanesljivo obratovanje omrežja in s tem zanesljivo dobavo električne energije končnim odjemalcem.

EEO je skupek elementov namenjenih napajanju nanj priključenih porabnikov. V posameznih elementih se odvijajo procesi transformacije (transformatorji), povezovanja (stikalne naprave – stikala, izolatorji, zbiralke ...), prenosa (vodi) in razdeljevanja (stikališča in transformatorske postaje) [2]. Pri načrtovanju elementov EEO oz. naprav se vse pogosteje uporabljajo različni pristopi, ki temeljijo na optimizacijskih algoritmih. Le-ti nam na koncu avtomatiziranega procesa cenitev KF najdejo optimalno rešitev za obravnavano napravo. Za cenitev KF v postopku načrtovanja izbrane naprave uporabljamo rezultate izračunov njenega matematičnega modela, modeliranje le-tega pa temelji na različnih metodah. Ena bolj razširjenih je modeliranje na osnovi metode končnih elementov (MKE), ki se uporablja kot orodje za reševanje parcialnih diferencialnih enačb (PDE). Ta metoda je osnova za simulacijska orodja, kot je nekomercialno programsko orodje EleFAnT ali pa komercialno programsko orodje FLUX, ki omogočajo načrtovanje, simulacijo ter analizo delovanja električnih naprav.

Prvi cilj disertacije je raziskati stanje in novosti na področju uspešnosti in učinkovitosti pogosto uporabljenih evolucionarnih algoritmov (angl. *Evolutionary Algorithms* – EA), naslednji cilj pa je na osnovi lastnih izkušenj in objavljenih rezultatov določiti algoritem, ki je primeren za uporabo na področju optimizacije naprav oz. elementov EEO. Eden izmed najpomembnejših ciljev disertacije je ustrezno modificirati in dopolniti izbrani

optimizacijski algoritem z namenom izboljšati dinamiko konvergence oziroma z drugimi besedami zapisano, skrajšati čas, ki je potreben za dokončanje optimizacijskega procesa. Naslednja dva cilja sta povezana s prilagodljivostjo algoritmov za njihovo aplikacijo na napravah oziroma elementih z različnimi specifikami in uporabo različnih programskih orodij za posredno ocenjevanje KF. Tako je eden od ciljev izdelava univerzalnega algoritma za načrtovanje naprav in identifikacijo parametrov, drugi pa je njegova nadgradnja, ki omogoča izvajanje parametrične analize. To orodje mora omogočati določitev trenda spreminjanja optimizacijskih parametrov v odvisnosti od števila delovanj modeliranega objekta oz. spreminjanja njegovega stanja, ki ima za posledico trajne spremembe na objektu zaradi zunanjih vplivov.

V postopku načrtovanja naprav v skladu z nekdanjo prakso se je v začetni fazi najprej definirala npr. geometrija in materiali obravnavane naprave. Določitev geometrije in izbira materialov je temeljila predvsem na izkušnjah načrtovalca ali na osnovi navodil ter ustreznih preglednic. Temu je sledilo modeliranje, izračuni in analiza rezultatov izračuna z namenom preverjanja ustreznosti delovanja naprave oz. skladnosti elementa s predpisanimi kriteriji [3]. Ponovni izračuni po spremembi geometrije in/ali materialov so se izvajali toliko časa, dokler ustrezno delovanje oz. skladnost ni bila zadovoljena. Slaba stran tega pristopa je njegova velika časovna zahtevnost, ki je posledica priprave modela ob vsaki spremembi parametrov. Ta slabost je pri načrtovanju, ki temelji na uporabi optimizacijskega algoritma, popolnoma odpravljena, saj je postopek načrtovanja avtomatiziran. Parametri oz. spremenljivke matematičnega modela se posodablajo brez intervencije uporabnika, celoten postopek pa vodi algoritem za načrtovanje naprave, ki vključuje tudi optimizacijski algoritem. Le-ta samostojno in po predpisanem principu generira parametre, ostali elementi algoritma za načrtovanje pa skrbijo za posodabljanje matematičnega modela obravnavane naprave, začetek in potek izračuna modela, branje oz. izvoz rezultatov izračunov ter cenitev KF. Takšen primer je podporni kompozitni izolator, kateremu v postopku načrtovanja optimiramo geometrijo tako, da dosežemo najbolj ugodno razporeditev električnega polja v njegovi okolici. Tako je kriterij optimizacije v tem konkretnem primeru *minimum* električne poljske jakosti, saj želimo vrednost v najbolj obremenjeni točki minimizirati, kolikor je le mogoče.

Optimizacijske metode v grobem delimo na deterministične in stohastične. Deterministične metode temeljijo na odvodu ali približku odvoda KF. V določenih primerih so te metode učinkovite in k rešitvi konvergirajo hitro oz. v malem številu iteracij. Njihova slabost se kaže predvsem v nezmožnosti učinkovitega odkrivanja lokacije globalnega optimuma, saj je uspešnost iskanja povsem odvisna od izbire začetne točke, v kateri se iskanje prične. Problem je namreč, da se te metode pogosto ujamejo v lokalni optimum, ki se nahaja v bližini začetne točke iskanja. Učinkovitost determinističnih metod pri iskanju globalnega optimuma je zagotovljena le takrat, ko sta izpolnjena dva pogoja, in sicer ko je KF vsaj dvakrat odvedljiva in ima en sam optimum, kar pa pri realnih tehniških problemih običajno ne drži [4].

EA kot stohastične metode so pri reševanju optimizacijskih problemov s področja tehnike v splošnem učinkoviti in zmožni obvladovati različne optimizacijske probleme velikih dimenzij. Pri svojem delovanju posnemajo naravno evolucijo, in tako spadajo med populacijske algoritme. Nedeterminističnost je tista lastnost EA, ki jim daje prednost pri preiskovanju večkriterijskih problemov ter problemov z več lokalnimi optimumi. Uporaba verjetnostnih mehanizmov je v tem primeru ključnega pomena pri odkrivanju globalno optimalne rešitve problema z več spremenljivkami (parametri). Verjetnostni mehanizmi namreč omogočajo skoke iz lokalnih optimumov. Ko omenjamo parametre, mislimo na spremenljivke, katerim optimizacijski algoritem spreminja vrednosti toliko časa, dokler v naprej predpisani kriterij ni zadovoljen oz. dokler ni najden minimum (optimum) KF. Kadar npr. obravnavamo geometrijo problema, je parameter lahko določena dimenzija problema, v primeru obravnave materialov problema pa bo parameter določena lastnost materiala. Parametrov samega optimizacijskega algoritma pri tem eksplicitno ne omenjamo zaradi zamenljivosti pojmov.

Pristop za načrtovanje, ki temelji na uporabi optimizacijskega algoritma, je mogoče prilagoditi drugačnim ciljem. Namesto zadovoljitve električnega ali kakšnega drugega kriterija, lahko z uporabo optimizacijskega algoritma dosežemo npr. zeleno delovanje ali odzive naprave. Postopek je v tem primeru inverzen, in sicer ob izpolnjeni zahtevi, da razpolagamo s podatki o delovanju naprave v obliki rezultatov meritev. V tem primeru govorimo o uglaševanju parametrov, s čimer lahko izboljšamo točnost matematičnega modela opazovanega objekta, in sicer tako, da poiščemo parametre modela, pri katerih se bodo izračunane oz. izhodne veličine samega modela čim boljše ujemale z izmerjenimi. Praktični primer je optimizacija modela plinskega odvodnika, pri katerem iščemo parametre modela, kot so napetost obloka, upornost razelektritve ipd., tako da se izračunani časovni odzivi modela plinskega odvodnika čim boljše ujema z izmerjenimi.

Drugi podoben primer je energetski transformator, kjer imamo nalogo identificirati snovne lastnosti materialov v napravi, katere natančna geometrija in s tem del matematičnega modela je popolnoma znan. Natančne podatke o geometriji, izvorih in robnih pogojih je v tem primeru enostavno pridobiti/izmeriti, medtem ko so lastnosti materialov, kot so toplotna prevodnost in toplotna kapaciteta ter koeficient sevanja in radiacije težko merljivi. Mejne in okvirne vrednosti so dostopne v raznih katalogih in literaturi, natančnejše vrednosti za konkretne materiale, ki so uporabljeni v opazovanem objektu, pa je mogoče identificirati na osnovi meritev in izračunov modela takrat, ko se izračunane, npr. toplotne razmere, ujema z izmerjenimi.

Prednost izdelanega pristopa za načrtovanje in optimizacijo naprav, ki temelji na uporabi optimizacijskega algoritma, je možnost vključitve poljubne stohastične optimizacijske tehnike v reševanje optimizacijskega problema ter neodvisnost od uporabnika. Uporaba tega avtomatiziranega pristopa pa zahteva poznavanje

obravnavega problema, sicer nas lahko postopek odvede k rezultatom optimizacije, ki so nedosegljivi zaradi tehnoloških omejitev pri izdelavi objekta ali se kažejo v obliki neobstojećih materialov oz. drugih neustreznih lastnosti le-teh.

V splošnem je pri reševanju realnih tehniških problemov največji problem zahteva po posredni cenitvi KF, in sicer s pomočjo računalniško zahtevnih orodij, ki npr. temeljijo na MKE metodi. V teh primerih so časi izračunov kompleksnejših matematičnih modelov kljub velikim zmogljivostim današnjih računalnikov relativno dolgi. Časi izračunov so v splošnem v rangu od nekaj minut do nekaj ur. Podedovana lastnost EA, in sicer počasna konvergenca optimizacijskega algoritma oz. veliko število iteracij (klicev KF) v kombinaciji s problemom kompleksnih matematičnih modelov pomeni dolgo trajajoče optimizacijske procese. Skupni čas trajanja optimizacijskega procesa lahko v takšnem primeru traja tudi več dni.

Eden izmed znanih EA – algoritmov diferenčne evolucije (DE) je kljub omenjeni podedovani slabosti, izbran kot primarna optimizacijska tehnika, in sicer predvsem zaradi njegove sposobnosti odkrivanja globalnega optimuma. Odločitev za uporabo DE je temeljila na lastnih izkušnjah z uspešnimi in učinkovitimi aplikacijami algoritma DE za reševanje optimizacijskih problemov v domeni EEO, npr. [5], [6], ter na osnovi pregleda aplikacij in rezultatov različnih optimizacijskih algoritmov na raznovrstnih električnih napravah in elementih, npr. [7]–[23].

V drugem poglavju disertacije so predstavljene osnove, ki so potrebne za razumevanje pojma "optimizacija". Pri tem je podano nekaj matematičnih osnov in definicij terminov, s katerimi se pri optimiranju tudi srečujemo. Prikazana je groba delitev optimizacijskih metod, nekatere izmed pomembnejših pa so tudi predstavljene. Prikazani so tudi rezultati oz. obnašanje posameznih metod pri reševanju izbranih optimizacijskih problemov oz. standardnih testnih funkcij.

V tretjem poglavju sta izvedeni dve razširitvi algoritma DE, in sicer razširitev osnovnega algoritma v algoritem za reševanje večkriterijskih problemov, prav tako pa je izvedena tudi razširitev algoritma, ki omogoča izkoriščanje nadomestnih modelov. Pri slednjem gre za izkoriščanje že izvedenih cenitev KF, s katerimi aproksimiramo topologijo v prostoru rešitev. Tako računsko zahtevne evalvacije kompleksnejših KF smiselno nadomeščamo z aproksimiranimi rešitvami, ki so tako časovno kot tudi računsko mnogo manj zahtevne. Metoda, ki se uporablja v okviru disertacije za aproksimacijo rešitev, se imenuje Kriging interpolacijska metoda. Novo razviti algoritem DE s Kriging podporo bistveno skrajšuje čas, ki je potreben za dokončanje optimizacijskega postopka.

V četrtem poglavju so podane teoretične osnove za izračune polj, ki so potrebne za obravnavo v disertaciji predstavljenih elementov EEO.

V petem poglavju so predstavljeni obravnavani elementi omrežja, njihove specifikke ter kriteriji za njihovo optimizacijo. Pri tem so prikazani primeri optimizacije podpornega

kompozitnega izolatorja, energetskega transformatorja, plinskega odvodnika prenapetosti, konfiguracije srednjenapetostnega omrežja ter skozijskega. Za vsak element posebej so podani tudi rezultati optimizacije.

V šestem poglavju je zapisan sklep oz. zaključki naloge ter predstavitev dosežkov.





## 2. OPTIMIZACIJA

Pri načrtovanju novih naprav oz. proizvodov se teži k njihovi tehnološki dovršenosti, učinkovitosti in zanesljivosti. V tem kontekstu je pomemben prav vsak posamezni element, ki je sestavni del širšega sistema in ima posledično vpliv na zanesljivost delovanja celotnega sistema. Novi koncepti načrtovanja izdelkov prav tako zahtevajo izdelavo proizvodov v čim krajšem času, doseganje tega cilja pa omogoča predvsem računalniško podprto načrtovanje z uporabo različnih optimizacijskih tehnik.

Optimizacija je maksimizacija želenih lastnosti sistema ob sočasni minimizaciji neželenih [24]. Lastnost, ki jo želimo optimirati, pa je prej potrebno matematično definirati oz. matematično zapisati v obliki KF. Pri tem je lahko optimum minimalna ali maksimalna vrednost KF, odvisno od preference. Optimum je tako ekstrem KF, pri tem pa je lahko ekstrem lokalni, če gledamo ozko področje okoli opazovane točke ali globalni, če opazujemo širše področje.

Ključna naloga vsakega optimizacijskega postopka je iskanje optimuma ustrezno definirane KF. Pri tem je zaželeno, da je vrednost KF iz iteracije v iteracijo ugodnejša, kar zagotavlja konvergenco postopka. Prav tako je zaželeno, da algoritem najde optimalno rešitev v čim manj iteracijah, kar zagotavlja učinkovitost postopka [25].

Cilj optimizacije je globalni optimum KF. V splošnem ima KF  $D$  parametrov, ki vplivajo na lastnost, ki jo optimiramo. Množica parametrov, pri kateri eksistira globalni optimum, pa je iskana optimalna rešitev  $\mathbf{x}$ .

Naravnavanje frekvence na radijskem sprejemniku je na primer poskus minimizacije šuma v signalu radijske postaje. Lastnost, ki jo želimo minimizirati, lahko matematično definiramo kot funkcijo spreminjanja kota gumba na radijskem sprejemniku  $\mathbf{x}$ :

$$f(\mathbf{x}) = \frac{\text{moč šuma}}{\text{moč signala}} \quad (2.1)$$

Ekstremi tovrstnih KF so cilj optimizacije. Naravnavanje frekvence radijskega sprejemnika vključuje eno samo spremenljivko, lastnosti kompleksnejših sistemov pa so običajno odvisne več kot od ene spremenljivke. V splošnem ima KF  $f(\mathbf{x}) = f(x_0, x_1, \dots, x_{D-1})$   $D$  parametrov, ki vplivajo na lastnost, ki jo optimiramo. Enoličnega pristopa, s katerim bi klasificirali KF ni, obstajajo pa določeni atributi, ki vplivajo na učinek posameznih optimizacijskih metod:

- *Kvantizacija oz. delitev parametrov*: Ali so spremenljivke KF zvezne ali diskretne? Ali so istega tipa?
- *Odvisnost parametrov*: Ali lahko parametre KF optimiramo ločeno?
- *Dimenzija*: Koliko spremenljivk definira KF?
- *Časovna odvisnost*: Ali je lokacija optimuma statična ali pa se s časom spreminja?
- *Modalnost*: Ali ima KF en sam ali več optimumov?
- *Omejitev*: Ali je KF omejena ali neomejena?
- *Odvedljivost*: Ali je KF odvedljiva v vseh točkah?

V primeru radijskega sprejemnika ima kot nastavitve gumba določeno realno vrednost in parameter je zvezen. Ni različnih tipov spremenljivk niti medsebojne odvisnosti parametrov, zato ker je dimenzija optimizacijskega problema  $D=1$ , torej je KF odvisna od enega samega parametra. Modalnost KF je odvisna od tega, kako je kot gumba za nastavljanje frekvence omejen. Če je omejen na bližino ene radijske postaje, potem je KF enomodalna, ker izkazuje en optimum. Če gumb pokriva širše področje z več radijskimi postajami in je cilj poiskati postajo z najmanjšim šumom, potem postane problem večmodalen. Če se frekvenca radijske postaje ne spreminja, je KF časovno neodvisna, prav tako KF v tem primeru tudi nima omejitev, sam gumb pa jo ima [24].

## 2.1 Matematično ozadje

V tem podpoglavju so predstavljene določene matematične definicije in določeni pojmi, ki so v nadaljevanju večkrat uporabljeni.

### 2.1.1 Minimum

Optimizacija določenega problema običajno vključuje minimizacijo KF  $f(\mathbf{x})$ , kjer je  $\mathbf{x}$  točka v prostoru optimizacijskih spremenljivk (prostor parametrov) oz. potencialna rešitev optimizacijskega problema. V splošnem bi lahko zapisali optimizacijski problem kot iskanje minimuma KF:

$$\min_{\mathbf{x} \in \mathbb{R}^D} f(\mathbf{x}) \quad (2.2)$$

Pri tem bomo optimizacijski problem klasificirali kot nelinearen in omejen problem, kjer iščemo vektor dimenzije  $D$ , ki je definiran kot:

$$\mathbf{x} = [x_0, x_1, \dots, x_{D-1}]^T \quad (2.3)$$

in zadošča  $(m'-1)$  enakostim oziroma  $m$  neenakostim:

$$\begin{aligned} c_i(\mathbf{x}) &= 0; \quad i = 1, 2, \dots, m'-1 \\ c_i(\mathbf{x}) &\geq 0; \quad i = m', \dots, m \end{aligned} \quad (2.4)$$

kjer so  $c_i(\mathbf{x})$  realne vrednosti skalarne funkcije, ki določajo omejitve spreminjanja optimizacijskih parametrov v  $\mathbf{x}$ . Vrednosti teh parametrov se torej nahajajo znotraj območja omejitev. Vsako točko  $\mathbf{x}$ , ki zadošča vsem omejitvam optimizacijskega problema, imenujemo kot dopustno rešitev. Vse možne točke predstavljajo področje dopustnih rešitev [26].

### 2.1.2 Lokalni in globalni minimum

Če funkcija  $u(\mathbf{x}^*, \delta)$  predstavlja nabor možnih rešitev v okolici lokalnega minimuma  $\mathbf{x}^*$ , mora za pogoj (2.5) veljati (2.6) [26]:

$$\mathbf{x} \in u(\mathbf{x}^*, \delta) \text{ in } \mathbf{x} \neq \mathbf{x}^* \quad (2.5)$$

$$f(\mathbf{x}^*) < f(\mathbf{x}) \quad (2.6)$$


Mnogi realni problemi imajo področja možnih rešitev, katera poleg globalnega velikokrat vsebujejo enega ali več lokalnih minimumov, ki zadovoljujejo (2.6). Pri nekaterih optimizacijskih problemih se zadovoljimo, če najdemo že lokalni minimum, medtem ko pa je pri drugih problemih globalni minimum edina sprejemljiva rešitev.

Točka  $\mathbf{x}^*$  je lokalni minimum če velja  $f(\mathbf{x}^*) \leq f(\mathbf{x})$  pri vseh  $\mathbf{x}$  v njeni  $\delta$  okolici, medtem ko je ista točka globalni minimum, če velja zgornji izraz za poljuben  $\mathbf{x}$ . Nasprotno

trditve veljajo za lokalni oz. globalni maksimum. Katerikoli globalni optimum je vedno hkrati tudi lokalni, medtem ko lokalni optimum ni nujno globalni [4], [24], [26].

Slabost determinističnih oz. gradientnih optimizacijskih metod je v tem, da običajno najdejo lokalni optimum, saj je njihova uspešnost v glavnem odvisna od izbire začetne točke iskanja. Če je KF definirana na zaprtem intervalu, potem globalni optimum na tem intervalu zagotovo obstaja. Tako je ena od možnosti, kako odpraviti omenjeno slabost, poiskati vse lokalne optime in med njimi izbrati globalnega.

V primerih, kjer je funkcija  $f$  dvakrat odvedljiva po eni spremenljivki, lahko s pomočjo stacionarne točke (točke, kjer je vrednost prvega odvoda funkcije  $f'(x)=0$ ) in s pomočjo predznaka drugega odvoda v stacionarni točki določimo, da je točka lokalni minimum, če velja  $f''(x)<0$ , lokalni maksimum pa, če velja  $f''(x)>0$  in prevoj ali sedlo, če velja  $f''(x)=0$ . Oblika ustreznih funkcij je prikazana na sliki 2.1 [27].



Slika 2.1: Predstavitev a) minimuma, b) maksimuma in c) sedla funkcije

### 2.1.3 Gradient, Hessianova matrika, Taylorjeva vrsta

Vrnimo se na minimizacijo funkcije  $f(\mathbf{x})$  z  $D$  spremenljivkami, kjer je  $\mathbf{x}=[x_1, x_2, \dots, x_{D-1}]^T$  in kjer so parcialni odvodi funkcije izračunljivi. Torej naj bo  $z=f(\mathbf{x})$  funkcija  $\mathbf{x}$ -a tako, da obstaja  $\partial f(\mathbf{x})/\partial x_i$  za vse  $i=1,2,\dots,D-1$ . Gradient funkcije  $f(\mathbf{x})$ , ki ga označujemo z matematičnim operatorjem *nabla*

$$\nabla = \left[ \frac{\partial}{\partial x_0}, \frac{\partial}{\partial x_1}, \dots, \frac{\partial}{\partial x_{D-1}} \right]^T \quad (2.7)$$

je vektor

$$\mathbf{g}(\mathbf{x}) = \nabla f(\mathbf{x}) = \left[ \frac{\partial f(\mathbf{x})}{\partial x_0}, \frac{\partial f(\mathbf{x})}{\partial x_1}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_{D-1}} \right]^T \quad (2.8)$$

Drugi odvod funkcije z  $D$ -spremenljivkami pripelje do zapisa Hessianove matrike [26]:

$$\mathbf{H}(\mathbf{x}) = \nabla(\nabla f(\mathbf{x}))^T = \nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f}{\partial x_0 \partial x_0} & \frac{\partial f}{\partial x_0 \partial x_1} & \cdots & \frac{\partial f}{\partial x_0 \partial x_{D-1}} \\ \frac{\partial f}{\partial x_1 \partial x_0} & & & \\ \cdots & & & \\ \frac{\partial f}{\partial x_{D-1} \partial x_0} & \cdots & \cdots & \frac{\partial f}{\partial x_{D-1} \partial x_{D-1}} \end{bmatrix} \quad (2.9)$$

Z uporabo matematičnega operatorja  $\nabla$  lahko KF zapišemo kot neskončno Taylorjevo vrsto [24]

$$\begin{aligned} f(\mathbf{x}) &= f(\mathbf{x}_0) + \frac{\nabla f(\mathbf{x}_0)}{1!}(\mathbf{x} - \mathbf{x}_0) + (\mathbf{x} - \mathbf{x}_0)^T \frac{\nabla^2 f(\mathbf{x}_0)}{2!}(\mathbf{x} - \mathbf{x}_0) + \dots \\ &= f(\mathbf{x}_0) + \mathbf{g}(\mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0) + (\mathbf{x} - \mathbf{x}_0)^T \frac{1}{2} \mathbf{H}(\mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0) + \dots \end{aligned} \quad (2.10)$$

kjer je  $\mathbf{x}_0$  točka, okoli katere je funkcija  $f(\mathbf{x})$  razvita. Za točko  $\mathbf{x}^*$ , pri kateri dosežemo minimum, mora veljati

$$\mathbf{g}(\mathbf{x}^*) = 0 \quad (2.11)$$

torej morajo vsi parcialni odvodi pri  $\mathbf{x} = \mathbf{x}^*$  biti enaki 0. V neposredni okolici  $\mathbf{x}_0$  imajo višji členi Taylorjeve vrste majhen prispevek, zato jih ni potrebno upoštevati. Po postopku, ki je predstavljen v [24] lahko iz Taylorjeve vrste v (2.10) gradient poljubne točke izrazimo kot

$$\nabla f(\mathbf{x}^*) = \mathbf{g}(\mathbf{x}_0) + \mathbf{H}(\mathbf{x}_0)(\mathbf{x}^* - \mathbf{x}_0) = 0 \quad (2.12)$$

kar lahko reduciramo na


$$\mathbf{x}^* = -\mathbf{g}(\mathbf{x}_0)\mathbf{H}^{-1}(\mathbf{x}_0) + \mathbf{x}_0 \quad (2.13)$$

Če je oblika enomodalne KF  $f(\mathbf{x})$  kvadratna, potem lahko izraz (2.13) uporabimo direktno za izračun njenega dejanskega minimuma, neodvisno od lokacije začetne točke  $\mathbf{x}_0$ .

#### 2.1.4 Eno- in večmodalne kriterijske funkcije


Za poljubno funkcijo lahko rečemo, da je enomodalna, če na opazovanem intervalu  $[a, x^*]$  njena funkcijska vrednost monotono upada, na podintervalu  $[x^*, b]$  monotono narašča, pri  $x^*$  pa zavzema najnižjo funkcijsko vrednost [27]. To pomeni, da ima KF na opazovanem intervalu en sam ekstrem, kot lahko vidimo na sliki 2.2, kjer imajo vse

narisane funkcije en globalni minimum in en globalni maksimum, in sicer na intervalu ali na njegovih mejah.



Slika 2.2: Predstavitev a) zvezne b) nezvezne c) omejene in d) diskretne funkcije

Seveda so mnogi problemi v praksi bolj komplicirani in posledično so KF večmodalne. Na sliki 2.3 so prikazane oblike nekaterih izmed teh KF [29].



Slika 2.3: Pregled oblike nekaterih KF

Slika 2.3 a prikazuje primer enomodalne funkcije, tj. funkcije z enim samim ekstremom. Prapodoba (angl. *Archetype*) tovrstne funkcije je  $D$ -dimenzijska kvadratna forma. Nekvadratne enomodalne KF običajno optimiramo s pomočjo zaporedja kvadratnih aproksimacij.

Slika 2.3 b predstavlja v osnovi enomodalno funkcijo. Zaradi motenj in drugih faktorjev je v praksi običajno, da je enostavna globalna struktura problema maskirana s parazitnimi lokalnimi optimumi. Do teh se opredelimo kot do nepomembnih in če lahko, KF zgladimo. S tem dejanjem dosežemo globalni optimum funkcije z večjo gotovostjo.

Na sliki 2.3 c je prikazana KF z globokim optimumom, na sliki 2.3 d pa funkcija z velikim številom pomembnih lokalnih ekstremov. Teh ne moremo ignorirati z glajenjem funkcije, pa tudi iskanje vseh s pričetkom v veliko naključno izbranih začetnih točkah bi lahko bilo neučinkovito. V teh primerih so najbolj učinkovite stohastične metode.

Večmodalna funkcija z malim številom pomembnih lokalnih optimumov je prikazana na sliki 2.3 e. V teh primerih se glajenja funkcije ne lotevamo, temveč poiščemo lokalne ekstreme. Če je njihovo število majhno, potem se lahko njihovega iskanja lotimo z determinističnimi metodami s pričetkom iskanja v več naključno izbranih začetnih točkah.

V primerih, ko postane KF ravna v okolici trenutne točke, kot je prikazano na sliki 2.3 f, predstavlja ravno področje "motnjo" za optimizacijski algoritem. V teh primerih je potrebno ravna področja funkcije označiti in okarakterizirati "nejasnost", katero predstavljajo.

### 2.1.5 Omejeni in neomejeni optimizacijski problemi

Cilj optimizacije je poiskati minimum ali maksimum danega problema, ki je lahko *omejen* ali *neomejen*. Za pojasniti pomena teh dveh pojmov, lahko kot primer vzamemo funkcijo  $f$  z eno spremenljivko in pri tem je problem [27]:

- *neomejen*, ko je katerikoli  $x \in \mathfrak{R}$  sprejemljiv,
- *omejen*, ko  $f$  minimiziramo z argumenti iz podmnožice  $S \neq \mathfrak{R}$ .

Teoretično so pri neomejenih problemih parametri prosti, v praksi pa običajno obstajajo omejitve in le-te lahko včasih izločijo tiste točke, pri katerih bi sicer funkcija imela globalni optimum.

## 2.2 Delitev optimizacijskih metod

Optimizacijske metode v grobem delimo na dva načina, in sicer na deterministične ali stohastične oz. na direktne ali indirektne.

Deterministične metode so lokalne optimizacijske metode, ki temeljijo na odvodu ali približku odvoda funkcije. V primeru, ko odvod KF ni izračunljiv, uporaba teh metod ni primerna. Še več, te metode so zelo občutljive na naključne motnje v obliki KF, v primeru večmodalnih KF pa običajno ne najdejo globalne rešitve.

Stohastične optimizacijske metode, kot so npr. Simulirano ohlajevanje (angl. *Simulated annealing*), Evolucijska strategija (angl. *Evolution strategies* – ES) in Genetski algoritem (angl. *Genetic algorithm* – GA) ne zahtevajo izračuna odvoda [28] in so zmožne obvladovati obsežne optimizacijske probleme. Prav tako so manj občutljive na naključne motnje v vrednostih KF. Največja slabost teh metod, v primerjavi z determinističnimi

metodami, je veliko število klicev KF. To dejstvo ima na prvi pogled še večji učinek, ko v obzir vzamemo posredne cenitve KF, ki temeljijo na časovno zahtevnih MKE izračunih. Kljub daljšemu času, potrebnemu za dokončanje optimizacijskega procesa, je zmožnost stohastičnih optimizacijskih metod poiskati globalni optimum tisto, kar jih naredi dovolj privlačne za uporabo [4].

## 2.2.1 Predstavitev nekaterih determinističnih optimizacijskih metod

Deterministične metode, kot npr. metoda strmega spusta (angl. *Steepest descent method*), metoda konjugiranih gradientov (angl. *Conjugate gradient method*) ter Newtonova metoda so precej priljubljene, ker so učinkovite in običajno konvergirajo k lokalnemu minimumu v majhnem številu iteracij.

### 2.2.1.1 Metoda strmega spusta

Metoda strmega spusta je najenostavnejša gradientna metoda za iskanje minimuma enomodalne in odvedljive KF. Pristop k reševanju problema po tej metodi je takšen, da predpostavimo, da je  $\mathbf{H}^{-1}(\mathbf{x}_0)$  v (2.13) možno nadomestiti z enotsko matriko  $\mathbf{I}$  [24]. Smer, v kateri iščemo minimum, je tista, v kateri funkcija  $f$  najhitreje upada. Ta smer je nasprotna gradientu funkcije  $f(\mathbf{x})$ :

$$\nabla f(\mathbf{x}) = \left( \frac{\partial f(\mathbf{x})}{\partial x_1}, \frac{\partial f(\mathbf{x})}{\partial x_2}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_D} \right) \quad (2.14)$$

ki lokalno kaže v smeri največje stopnje rasti funkcije. Od tod sledi da  $-\nabla f(\mathbf{x})$  kaže v smeri največjega upada. Iskanje minimuma se začne v poljubni točki  $\mathbf{x}_0$ , iz katere se pomikamo v nasprotno smer glede na orientacijo gradienta, vse dokler ne pridemo dovolj blizu rešitvi oz. minimumu funkcije. Nadomestitev v izrazu (2.13) z enotsko matriko ne vodi direktno k minimumu, temveč v točko:

$$\mathbf{x}_1 = \mathbf{x}_0 - \mathbf{g}(\mathbf{x}_0) \quad (2.15)$$

kjer je  $\mathbf{g}(\mathbf{x}_0)$  gradient v dani točki [24], [30]. Ker negativna vrednost gradienta kaže v smeri upadanja vrednosti funkcije, bo  $\mathbf{x}_1$  bližje minimumu, kot je to bil  $\mathbf{x}_0$ , razen če korak pomika ni prevelik. Dodajanje velikosti koraka  $h$  v člen, ki definira smer, vnaša možnost nadzora pri minimizaciji funkcije. Enačbo (2.15) sedaj zapišimo v splošni obliki in vključenim faktorjem, ki določa velikost koraka  $h$ :

$$\mathbf{x}_{k+1} = \mathbf{x}_k - h\mathbf{g}(\mathbf{x}_k) \quad (2.16)$$



Ker smo v postopku minimizacije, je cilj narediti premik v točko s čim nižjo funkcijsko vrednostjo. Za doseganje tega cilja izvedemo minimizacijo funkcije  $f(\mathbf{x}_{k+1})$ , kar imenujemo tudi linearno iskanje. Ko imamo določen  $h$  pri katerem ima ta funkcija minimum, lahko z enačbo (2.16) izrazimo točko  $\mathbf{x}_{k+1}$ , v katero izvedemo premik.

### ***Pregled metode strmega spusta***

Pričnemo v začetni točki  $\mathbf{x}_k$  in postavimo  $k$  na  $k = 0$ .

1. Izračunamo gradient v začetni točki  $\mathbf{g}(\mathbf{x}_k)$  oz. smer, v kateri iščemo minimum:  
 $\mathbf{s}_k = -\nabla f(\mathbf{x}_k)$ .
2. Izvedemo enoparametersko minimizacijo funkcije  $z(h)$  oz. (2.16) in določimo  $h_{\min}$ .
3. Izračunamo točko, v katero izvedemo premik:  $\mathbf{x}_{k+1} = \mathbf{x}_k + h_{\min} \mathbf{s}_k$ .
4. Zaustavimo postopek minimizacije, če je izpolnjen pogoj  $\|f(\mathbf{x}_{k+1}) - f(\mathbf{x}_k)\| \leq \varepsilon$ .

Ponovitev postopka:  $k = k + 1$ .

Metoda strmega spusta je preprosta in enostavna. Njena prednost pred ostalimi gradientnimi metodami je računska nezahtevnost, po drugi strani pa ima pomembno slabost – v splošnem zelo počasno konvergenco. Bližje kot je minimumu, konvergenca postaja bolj počasna.

#### **2.2.1.2 Metoda konjugiranih gradientov**

Princip gradientnih metod je takšen, da pričnemo z iskanjem minimuma v neki začetni točki  $\mathbf{x}_0$ , v vsaki iteraciji pa izračunamo  $\mathbf{x}_{k+1}$  kot točko, ki minimizira funkcijo  $f$  vzdolž nove smeri, dobljene s pomočjo smeri lokalnega gradienta. Ta metoda ni preveč učinkovita, saj moramo pri pomikanju k minimumu funkcije v vsakem koraku iti v pravokotni smeri glede na predhodno, ki pa običajno ni smer, ki bi kazala v smeri minimuma funkcije. Zaradi tega bi želeli izbrati novo smer na osnovi nasprotne smeri lokalnega gradienta in hkrati konjugirano prejšnjim smerem.

Metoda konjugiranih gradientov se sestoji iz iterativnih korakov, v katerih je preiskovanje prostora izvedeno v konjugiranih smereh, kar pomeni, da sta dva različna vektorja  $\mathbf{s}_i$  in  $\mathbf{s}_j$  ortogonalna glede na poljubno pozitivno definitno in simetrično matriko, npr.  $\mathbf{A}$  [31]:

$$\mathbf{s}_i^T \mathbf{A} \mathbf{s}_j = 0 \tag{2.17}$$

kjer je v  $D$ -dimenzijskem prostoru  $D$  konjugiranih smeri. Pri metodi konjugiranih gradientov so smeri konjugirane glede na Hessianovo matriko oz.  $f''$ .

V vsakem koraku metode določimo novo točko, v katero se pomaknemo z izrazom

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{s}_{k+1} \quad (2.18)$$

vrednost  $\alpha_k$  pa je nastavljena tako, da predstavlja tisto vrednost, ki minimizira  $f(\mathbf{x}_{k+1})$  in definira minimum vzdolž smernega vektorja  $\mathbf{s}_{k+1}$ . Smerni vektor za korak  $k+1$  je določen z izrazom

$$\mathbf{s}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{s}_k \quad (2.19)$$

kjer je  $\beta_k$  izbran tako, da je  $\mathbf{s}_{k+1}$  konjugiran glede na prejšnje smeri oz. smerne vektorje. Vidimo, da je nova smer iskanja minimuma v vsakem koraku izračunana kot linearna kombinacija trenutnega gradienta in predhodne smeri s faktorjem  $\beta_k$ , ki je izračunan kot razmerje vrednosti trenutnega in predhodnega gradienta:

$$\beta_k = \frac{\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}}{\mathbf{g}_k^T \mathbf{g}_k} \quad (2.20)$$

### **Pregled metode konjugiranih gradientov**

Pričnemo v točki  $\mathbf{x}_k$  in postavimo števec  $k$  na vrednost  $k=0$  [32], [33]. Dalje izračunamo vrednost gradienta  $\mathbf{g}_0 = \nabla f(\mathbf{x}_0)$  in smerni vektor kot  $\mathbf{s}_0 = -\mathbf{g}_0$ .

1. Poiščemo  $\alpha_k$ , ki minimizira enoparametersko funkcijo  $\phi(\alpha_k) = f(\mathbf{x}_k + \alpha_k \mathbf{s}_k)$  in zapišemo izraz za izračun naslednje točke  $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{s}_k$ .
2. Ovrednotimo gradient  $\mathbf{g}_{k+1}$  v novi točki.
3. Izračunamo faktor  $\beta_k = \mathbf{g}_{k+1}^T \mathbf{g}_{k+1} / \mathbf{g}_k^T \mathbf{g}_k$ .
4. Izračunamo novi smerni vektor  $\mathbf{s}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{s}_k$ .
5. Zaustavimo postopek optimizacije, če je izpolnjen pogoj  $\|f(\mathbf{x}_{k+1}) - f(\mathbf{x}_k)\| \leq \varepsilon$ .

Ponovitev postopka:  $k = k + 1$ .

Prvi korak te metode je enak kot pri metodi strmega spusta, vsak naslednji korak pa pomeni pomik v smeri, ki je linearna kombinacija smeri trenutnega gradienta in prejšnjih smernih vektorjev. V koraku  $k$  ovrednoti trenutni negativni gradient in mu doda linearno kombinacijo prejšnjih smernih vektorjev z namenom pridobiti nove konjugirane smeri, vzdolž katere se pomika. Metoda konjugiranih gradientov tako v

splošnem konvergira mnogo hitreje kot metoda strmega spusta. Ta trditev drži še posebej, če je funkcija zvezna in gladka, prav tako pa se mora začetna točka nahajati v bližini lokalnega minimuma.

### 2.2.1.3 Newtonova metoda

Newtonova metoda se od metode strmega spusta in metode konjugiranih gradientov razlikuje po uporabi informacije o drugem odvodu pri lociranju minimuma funkcije  $f(\mathbf{x})$ . Rezultat vključitve informacije o drugem odvodu je hitrejša konvergenca in pa ne nujno krajši čas izračuna. Izračun drugega odvoda in obdelava Hessianove matrike sta lahko časovno zelo zahtevna, posebej v primeru problemov večjih dimenzij [34].

Ideja metode je aproksimirati dano funkcijo  $f(\mathbf{x})$  v vsaki iteraciji s kvadratno funkcijo

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x} + b \mathbf{x} + c \quad (2.21)$$

nato pa sledi premik k minimumu te kvadratne funkcije. Kvadratno funkcijo za točko  $\mathbf{x}$  v neposredni okolici trenutne točke  $\mathbf{x}_k$  lahko zapišemo z nekaj členi Taylorjeve vrste ( $\Delta \mathbf{x} = \mathbf{x} - \mathbf{x}_k$ ):

$$f(\mathbf{x}_k + \Delta \mathbf{x}) = f(\mathbf{x}) = f(\mathbf{x}_k) + \mathbf{g}_k (\mathbf{x} - \mathbf{x}_k) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_k)^T \mathbf{H}(\mathbf{x}_k) (\mathbf{x} - \mathbf{x}_k) \quad (2.22)$$

kjer sta  $\mathbf{g}_k$  gradient in  $\mathbf{H}_k$  Hessianova matrika funkcije  $f$  ovrednotene v točki  $\mathbf{x}_k$ . Pojavljata se v drugem in tretjem členu Taylorjeve vrste. Odvod (2.22) je:

$$\nabla f(\mathbf{x}) = \mathbf{g}_k + \frac{1}{2} \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k) + \frac{1}{2} \mathbf{H}_k^T (\mathbf{x} - \mathbf{x}_k) \quad (2.23)$$

Hessianova matrika je vedno simetrična, če je funkcija dvakrat zvezno odvedljiva v vsaki točki. Izraz (2.23) lahko poenostavimo:

$$\nabla f(\mathbf{x}) = \mathbf{g}_k + \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k) \quad (2.24)$$

Če predpostavimo, da  $f(\mathbf{x})$  zavzame minimum pri  $\mathbf{x} = \mathbf{x}^*$ , je gradient

$$\mathbf{g}_k + \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k) = 0 \quad (2.25)$$

z rešitvijo  $(\mathbf{x}^* - \mathbf{x}_k) = \Delta \mathbf{x} = -\mathbf{g}_k \mathbf{H}_k^{-1}$ . S to rešitvijo v vsaki iteraciji izračunamo novo točko

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_k^{-1} \mathbf{g}_k \quad (2.26)$$

kjer je člen  $-\mathbf{H}_k^{-1} \mathbf{g}_k$  večkrat omenjen kot Newtonova smer.

V primeru, ko je aproksimacija v (2.22) ustrezna, bo metoda konvergirala v le nekaj iteracijah. Na primer, če je funkcija, ki jo optimiramo  $f(\mathbf{x})$  kvadratna funkcija dimenzije  $D$ , bo metoda konvergirala k rešitvi v eni sami iteraciji, iz katere koli začetne točke. Kljub temu da je videti, da je konvergenca hitra, sodeč po številu iteracij, vsaka iteracija vključuje izračun drugega odvoda in obravnavo Hessianove matrike. Lastnosti metode so zatorej zelo odvisne od določenih kvalitet te matrike. Ena od teh kvalitet je pozitivna definitnost matrike. Da metoda konvergira k minimumu, mora biti Newtonova smer, smer spusta. Za to zahtevamo:

$$\nabla f(\mathbf{x}_k) \mathbf{s}_k = \mathbf{g}_k^T (\mathbf{x}_{k+1} - \mathbf{x}_k) < 0 \quad (2.27)$$

kar z vstavitvijo v (2.26) da:

$$-(\mathbf{x}_{k+1} - \mathbf{x}_k)^T \mathbf{H}_k (\mathbf{x}_{k+1} - \mathbf{x}_k) < 0 \quad (2.28)$$

Neenakost je zadovoljena v vseh točkah, za katere velja  $\mathbf{x}_{k+1} - \mathbf{x}_k \neq 0$ , če je  $\mathbf{H}_k$  pozitivno definitna in simetrična matrika.

Metoda strmega spusta v nasprotju z Newtonovo metodo potrebuje informacijo o gradientu za izbiro smeri pomika in linijsko minimizacijo oz. iskanje v tej izbrani smeri za določitev koraka pomika. Ti hitri koraki imajo lahko večjo prednost pred hitro konvergenco Newtonove metode v primeru večjih dimenzij  $\mathbf{x}$ -a. Metoda konjugiranih gradientov ima pospešeno konvergenco v primerjavi z metodo strmega spusta, vendar brez časovnih in spominskih obremenitev Newtonove metode.

### **Pregled Newtonove metode**

Pričnemo v točki  $\mathbf{x}_k$  in postavimo števec  $k$  na vrednost  $k = 0$ .

1. Izračunamo gradient  $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$  in Hessianovo matriko  $\mathbf{H}_k = \nabla^2 f(\mathbf{x}_k)$ .
2. Določimo smer iskanja  $\mathbf{s}_k = -\mathbf{H}_k^{-1} \mathbf{g}_k$ .
3. Izračunamo novo točko  $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{s}_k$ .
4. Zaustavimo postopek optimizacije, če je izpolnjen pogoj  $\|f(\mathbf{x}_{k+1}) - f(\mathbf{x}_k)\| \leq \varepsilon$ .


Ponovitev postopka:  $k = k + 1$ .

Kljub omenjenim težavam Newtonove metode je le-ta precej popularna in se uporablja, zahvaljujoč njeni hitri konvergenci, v primeru, ko se iskanje prične v zadostno mali okolici rešitve. Konvergenca te metode je kvadratna, medtem ko je pri metodi strmega spusta v najboljšem primeru linearna.

Največja slabost metode je nezanesljivost. Bolj oddaljena kot je točka  $x_k$  od rešitve, kvadratna aproksimacija v (2.22) postane slabša, kar lahko povzroči, da Hessianova matrika ni pozitivno definitna in simetrična. V tem primeru metoda več ne bo vodila k minimumu. Newtonove metode tako ni nujno globalno konvergentna, kar pomeni, da ni nujno da bo konvergirala s pričetkom iz katerekoli začetne točke.


#### 2.2.1.4 Primerjava predstavljenih determinističnih metod na analitično zapisanih funkcijah

V splošnem lahko deterministične metode, predstavljene v poglavju 2.2.1, uporabljamo za optimizacijo  $D$ -dimenzijskih funkcij. Za grafično predstavitev delovanja metod sta v nadaljevanju uporabljeni dve 2D funkciji, ki sta predstavljeni na sliki 2.4.




Slika 2.4: Testni 2D funkciji

Za predstavljene metode je prikazan potek iskanja minimuma testne funkcije s slike 2.4 a. Na sliki 2.5 so tako prikazane konture grafa te funkcije ter poti oz. trajektorije, po kateri je posamezna metoda prišla iz začetne točke v končno točko oz. minimum. Enako so na sliki 2.6 prikazane konture in poti približevanja minimumu za funkcijo s slike 2.4 b.



Slika 2.5: Konture grafa funkcije s slike 2.4 a in trajektorije približevanja k minimumu za a) metodo strmega spusta, b) metodo konjugiranih gradientov in c) Newtonovo metodo



Slika 2.6: Konture grafa funkcije s slike 2.4 b in trajektorija približevanja k minimumu za a) metodo strmega spusta, b) metodo konjugiranih gradientov in c) Newtonovo metodo

Za primer KF s slike 2.4 a do rešitve oz. minimuma pridemo z metodo strmega spusta v 15-ih iteracijah, z metodo konjugiranih gradientov v dveh iteracijah in z Newtonovo metodo v praktično eni iteraciji. KF s slike 2.4 b je precej težavna za metodo strmega spusta, saj minimum ni bil dosežen niti po 2000 iteracijah, kar pa na sliki 2.6 a ni vidno, saj je metoda sicer prišla v neposredno okolico optimuma, ni ga pa dosegla. Metoda konjugiranih gradientov (slika 2.6 b) je bila v tem primeru uspešna in je do minimuma prišla v 21 iteracijah, pri Newtonovi metodi (slika 2.6 c) pa je bil optimum dosežen v le 5-ih iteracijah, s tem da so določeni koraki na slikah zelo majhni in posledično tudi niso vidni.

Kot je že bilo omenjeno, o hitrosti metode ne moremo soditi po številu iteracij, saj se npr. pri Newtonovi metodi znotraj ene iteracije vrši matematična operacija invertiranja matrike, ki pa je lahko časovno zelo zahtevna. V prikazanem primeru imamo opravka s funkcijo dveh spremenljivk, torej je Hessianova matrika dimenzije  $2 \times 2$ , invertiranje matrik malih dimenzij pa ni časovno zahtevno.

## 2.2.2 Predstavitev nekaterih stohastičnih optimizacijskih metod

Stohastični optimizacijski algoritmi, kot so npr. GA, ES in DE, so evolucijski algoritmi, ki posnemajo naravno evolucijo. Pristop deluje tako, da se navadno naključno generira začetna *populacija osebkov*, le-ti pa se skozi evolucijo razvijajo s pomočjo naključnih procesov *selekcije*, *križanja* in *mutacije*. Bolje ocenjeni osebki (z ugodnejšo vrednostjo KF) so favorizirani in se pogosteje križajo kot slabši. S tem se izmenjuje boljši genski material med osebki, mutacija pa prinaša naključne spremembe osebkov oz. nove lastnosti v okolje. Drugače zapisano, v naravni evoluciji samo najboljši osebki prenašajo svoje gene v naslednjo generacijo, slabše osebke pa evolucija izloči.

EA torej posnemajo princip naravne evolucije, v zvezi z njim pa se uporablja tudi za to področje značilna terminologija. Tako operirajo nad osebki (rešitvami v prostoru stanj) in populacijami (množica takšnih rešitev). Z uporabo selekcije in križanja osebkov ustvarjajo iz generacije v generacijo boljše rešitve [35]. V kontekstu EA so do sedaj omenjeni biološki termini dejansko uporabljeni v analogiji z resnično biologijo, zato so nekateri v nadaljevanju tudi predstavljeni [37], in sicer:

- **Osebek** je osnovna enota in predstavlja kandidata za rešitev optimizacijskega problema, ki ga rešujemo.
- **Populacija** je skupina osebkov, ki obstajajo hkrati. Navadno omenjamo dve populaciji tj. populacijo staršev in populacijo potomcev. V vsakem koraku iz populacije staršev s pomočjo genetskih operatorjev dobimo populacijo potomcev.
- **Generacija** je izraz, s katerim želimo označiti populacijo kot del evolucije. Govorimo npr. o prvi, drugi ..., *i*-ti populaciji.
- **Selekcija** je izbiranje posameznih osebkov iz populacije. Ti potem običajno predstavljajo podlago za nastanek nove generacije. Zato je pomembno, da pri selekciji izberemo boljše osebkove populacije.
- **Križanje** je genetski operator, ki deluje na osebkih populacije (starša) in nam vrne nove osebkove (potomce).
- **Mutacija** je genetski operator, ki deluje na posameznem osebkove tako, da ga (po navadi) naključno spremeni.

Dobre lastnosti EA so robustnost in neobčutljivost, sposobnost poiskati globalni optimum ter visoka stopnja prilagodljivosti pri integracijah v algoritme za načrtovanje objektov s področja tehnike. Po drugi strani lahko kot bistveno slabost navedemo dejstvo, da je pri mutacijah (naključni procesi) večkrat potrebna sreča za hitro konvergenco. Konvergenca nam pove, ali se in kam se za dani problem stečejo rešitve (populacija osebkov), dinamika konvergence pa pove, kako hitro algoritem najde rešitev [25]. Pod pojmom konvergenca razumemo konvergenco populacije, ki z drugimi besedami pomeni izgubo oz. zmanjšanje njene raznolikosti [39]. Slabost EA v primerjavi z determinističnimi metodami je počasna dinamika konvergence. To z drugimi besedami pomeni večje število cenitev KF oz. daljši čas, ki je potreben za dokončanje optimizacijskega postopka. Kljub omenjeni slabi lastnosti je zmožnost EA odkriti globalni optimum tista lastnost, ki popularizira rabo algoritmov iz te skupine.

### 2.2.2.1 Genetski algoritem

Algoritem predstavlja močno optimizacijsko orodje, ki pogosto najde globalno optimalno rešitev tudi pri zelo zapletenih pogojih. Seveda pa GA optimalne rešitve ne najdejo vedno. Še več, tudi daljši časi izvajanja algoritma nam ne zagotavljajo, da bodo našli optimalno rešitev. Ko pa želimo izdelati GA, moramo najprej izbrati način zapisa podatkov. Nato se moramo odločiti za tip selekcije in za genetske operatorje. Na koncu moramo določiti še vse parametre, ki jih bomo uporabljali v algoritmu [37].

#### **Zapis podatkov**

Vrsta zapisa podatkov je pomemben faktor, ki odloča o učinkovitosti izvajanja algoritma. Kodiranje osebkov (kromosomov) z geni, ki so binarne številke vnaprej določene dolžine, je najbolj razširjena predstavitev kromosoma zaradi svoje preprostosti in sledljivosti. V tem primeru ima vsako mesto v kromosomu samo eno od dveh možnosti: 0 ali 1. Redkeje se za zapis kromosomov uporablja bolj naraven način, ki je odvisen od problema in namesto bitov uporablja prilagojene podatkovne strukture. Eden takšnih zapisov je zapis z vektorji [37].

#### **Selekcija**

Ko smo se odločili za zapis, je naslednji korak izbira načina selekcije. Najprej moramo osebkom izračunati vrednost KF, ki služi za oceno njegove kvalitete glede na ostale osebkke v populaciji.

Ocenjevanje je pomembna povezava med GA in sistemom, ki ga optimiramo. Večja kot je ocena kvalitete osebkka, večja je verjetnost, da bo preživel. S tem dobimo operacijo reprodukcije, ki predstavlja kopiranje osebkka iz trenutne v naslednjo generacijo, pri čemer imajo boljši osebkki več kopij kot slabši.

Da bi generirali dobre potomce oz. novo generacijo, je potrebno pred križanjem izvesti selekcijo staršev. Namen selekcije je poudariti dobre osebkke v upanju, da bodo njihovi potomci še boljši. Če je selekcija premočna, iz populacije izloči slabše osebkke, ki so potrebni za raznolikost populacije, če pa je prešibka, je evolucija prepočasna. Zato moramo poiskati pravi način selekcije, ki bo pripeljal do dobrih rešitev. V uporabi so naslednje metode selekcije [37]:


- Selekcija z ruleto (angl. *Roulette Wheel Selection*); pri tem tipu selekcije je verjetnost, da bo osebek izbran, sorazmerna z njegovo kakovostjo  $q$ . To si lahko predstavljamo kot kolo (slika 2.7), ki je razdeljeno na toliko delov, kolikor je



osebkov v populaciji. Velikost posameznega dela je glede na sorazmernost s kakovostjo določena s koeficientom:

$$\frac{q(i)}{\sum_i q(i)} \quad (2.29)$$

Če tako kolo zavrtimo, se bo ustavilo na določenem osebkju z verjetnostjo, ki je sorazmerna z njegovo kakovostjo.



Slika 2.7: Selekcija z ruleto


- Elitizem se v mnogih GA izkaže za zelo učinkovit prijem za pospeševanje konvergence, uporablja pa se kot dodatek k selekciji, pri katerem določeno število najboljših osebkov prestavimo v populacijo potomcev brez sprememb. Na tak način ne izgubimo najboljših rešitev [37]. Slabost elitizma je, da z njim obstaja možnost, da se algoritem ujame v kakšen lokalni optimum [40].
- Tekmovalna selekcija (angl. *Tournament Selection*); v tem primeru sta iz populacije izbrana dva naključna osebkja. Temu sledi prav tako naključna izbira števila  $r$ , ki je med 0 in 1. Če je  $r$  manjši od določene vrednosti (npr. 0,7), izberemo boljšega izmed osebkov, sicer pa slabšega. Osebkja se nato vrmeta v začetno populacijo in sta lahko še večkrat izbrana.
- Počasna selekcija (angl. *Steady-state Selection*); pri tem tipu selekcije se v vsaki generaciji spremeni le nekaj slabših osebkov, ki jih zamenjajo najboljši potomci. Ta pristop se uporablja v primerih, ko problem rešujejo vsi osebki skupaj in ne le posamezen najboljši osebek.

### **Genetski operatorji**

Izbira genetskih operatorjev je močno pogojena z načinom zapisa problema. Najpogosteje uporabljani operatorji so:


- *Križanje*: če imamo osebkje zapisane z dvojiškimi nizi, je na voljo več načinov križanja, kjer kombiniramo genski material naključno izbranih parov osebkov.

Najenostavnejše je križanje z eno samo točko križanja (slika 2.8), od katere si starša izmenjata ves zapis.




Slika 2.8: Križanje z eno točko

Slaba lastnost takega načina križanja je, da ne doseže vseh mogočih rešitev z enako verjetnostjo. Zato je pogosto v uporabi križanje z več točkami (slika 2.9), pri katerem si starša izmenjata vse gene med točkama.



Slika 2.9: Križanje z dvema točkama

Naslednji način križanja je znan kot *uniformno križanje* (slika 2.10). Pri tem križanju se tvorita potomca s pomočjo maske križanja. Število učinkovitih točk križanja ni določeno, njihova povprečna vrednost pa je  $l/2$ , kjer je  $l$  število genov v kromosomu [41]. Zaradi naključno izbranih bitov v maski križanja obstaja tendenca križanja posameznih genov znotraj kromosoma, kar razbija gradnike kromosoma in posledično slabša lastnosti konvergence ter hkrati večja natančnost pri iskanju optimuma. V literaturi ne najdemo pravih argumentov, ki bi kazali, katera izmed tehnik križanja je boljša.



Slika 2.10: Primer uniformnega križanja

- *Mutacija*: čeprav je križanje glavna operacija, se uporablja tudi mutacija, tj. naključno spreminjanje genskega materiala posameznim osebkom (ne vsem). Tudi ta operacija ima podobnost v naravi, kjer mutacija pomeni regeneriranje izgubljenega genskega materiala. Kadar se določen del genskega materiala na kakršen koli način izgubi, ga osebek znova generira, vendar naključno. V algoritmu mutacija navadno spremeni naključni del kromosoma. Če so ti zapisani v dvojiškem nizu, to pomeni, da se pri mutaciji naključni gen spremeni iz 0 v 1 ali obratno. Ta operacija se izkaže za zelo pomembno, ker se brez nje lahko zgodi, da se GA ujame v lokalni minimum, iz katerega ne najde več poti. V tem primeru mutacija poskrbi za ustvarjanje raznolikosti genskega materiala.
- *Strategija parjenja*: poleg križanj in mutacij se uporabljajo tudi drugi genetski operatorji. Zanimiv je pristop, ki pomaga ohranjati raznolikost osebkov v populaciji. To je dodajanje pogojev za parjenje. Na primer, če sta si dva osebka preveč podobna, parjenje prepovemo (incest).

GA se med seboj razlikujejo tudi po tem, ali v postopku dovoljujejo nedopustne rešitve. Po delovanju genetskih operatorjev se namreč rešitve lahko pokvarijo oz. postanejo nedopustne. Za rešitev tovrstnega problema je več poti. Nekateri algoritmi v samih genetskih operatorjih poskrbijo za to, da rešitve ostajajo dopustne, nasprotno pa drugi algoritmi dovolijo, da genetski operatorji naredijo rešitve nedopustne, te pa mora nato algoritem pred ocenjevanjem popraviti. Spet nekateri algoritmi pa dovolijo, da nedopustne rešite obstajajo skozi celotno evolucijo, vendar take rešitve pri vrednotenju kakovosti označijo kot zelo slabe [37].

### **Parametri**

Da je GA zadovoljivo učinkovit, je potrebno poiskati pravo ravnotežje med selekcijo, križanjem in mutacijo. To ravnotežje je odvisno tudi od KF in oblike zapisa rešitve. Poleg tega se koristnost križanj in mutacij s potekom genetskega algoritma spreminja. Zato je zelo pomembno, kakšne parametre izberemo [37]. Univerzalni ključ, po katerem bi te parametre optimizacije določali, ne obstaja. Navadno se jih določa eksperimentalno in se od problema do problema razlikujejo.

Eden izmed parametrov GA je tudi zaustavitveni kriterij. To je parameter, ki nam pove, kdaj naj končamo evolucijo. Najbolj pogosto uporabljeni kriterij zaustavitve algoritma je v naprej določeno število generacij ali pa razvijamo populacijo in se ustavimo, ko se najboljša znana rešitev v zadnjih nekaj korakih ni spremenila.

## **Delovanje GA po korakih**

*Določitev prve generacije:* prva generacija je sestavljena iz dopustnih rešitev za dani problem. Ta generacija običajno nima kvalitetnih rešitev.

*Ocenjevanje:* za ocenjevanje posameznih osebkov trenutne populacije uporabljamo KF. Ocena je določeno število, ki predstavlja kakovost osebka.

*Zaustavitev izvajanja algoritma:* algoritem ustavi evolucijo, ko je zadoščeno zaustavitvenemu kriteriju. To je lahko takrat, ko so osebki dovolj kvalitetni ali npr. ko algoritem doseže vnaprej določeno število generacij.

*Glavni del GA:* ta del predstavlja postopek, ki iz populacije staršev naredi populacijo potomcev. Na ocenjeni populaciji staršev najprej izvedemo selekcijo. Najboljši osebki nam predstavljajo elito, ki se brez križanj in mutacij prepíšejo v populacijo potomcev. V nadaljevanju nato do zapolnitve celotne populacije potomcev ponavljamo naslednje:

- S selekcijo izberemo starše. V primeru selekcije z ruleto v vsakem koraku izberemo dva starša z verjetnostjo, ki je sorazmerna njuni kakovosti.
- Starša križamo in s tem dobimo dva potomca.
- Na potomcih uporabimo mutacijo in ju nato dodamo v populacijo potomcev.

Ko je populacija potomcev zapolnjena, nadaljujemo z ocenjevanjem ter s ponavljanjem zaporedja korakov [37].

### **2.2.2.2 Evolucijska strategija**

ES uvrščamo med stohastične metode evolucijskega računanja. V zadnjem času je najbolj razširjen ti.  $(\mu/\rho, \lambda)$  model ES, kjer se znotraj populacije vršijo štiri genetski procesi, in sicer reprodukcija, mutacija, križanje in selekcija. Pri tem modelu začetni proces naključno generira populacijo staršev velikosti  $\mu$ , ki je omejena z optimizacijskimi parametri. V naslednjem koraku  $\rho$  staršev, nastalih z reprodukcijo iz prejšnjega koraka, ustvari z rekombinacijo  $\lambda$  (nemutiranih) potomcev. Rekombinacija se v celoti opravi nad starševsko populacijo, in sicer lahko izbiramo med *diskretno* in *vmesno* rekombinacijo. Pri diskretni rekombinaciji se posamezne komponente naključno izbirajo bodisi iz prvega bodisi iz drugega starševskega osebka in tako tvorijo potomca, medtem ko so pri vmesni rekombinaciji vrednosti posameznih komponent potomca nekje vmes med vrednostmi pripadajočih komponent pri obeh starših. Združitev lastnosti dveh staršev  $\mathbf{x}_{s1}$ ,  $\mathbf{x}_{s2}$  z vmesnim križanjem privede do nastanka dveh novih potomcev  $\mathbf{x}_{p1}$ ,  $\mathbf{x}_{p2}$ , pri čemer faktor  $b_v$  izberemo ustrezno iz intervala  $[0,1]$ .

$$\begin{aligned} \mathbf{x}_{p1} &= b_v \mathbf{x}_{s1} + (1 - b_v) \mathbf{x}_{s2} \\ \mathbf{x}_{p2} &= b_v \mathbf{x}_{s2} + (1 - b_v) \mathbf{x}_{s1} \end{aligned} \quad (2.30)$$

Korak mutacije se za vseh  $\lambda$  potomcev izvede z dodajanjem vektorja naključno izbranih števil k obstoječemu vektorju parametrov  $\mathbf{x}$ . Pred tem se še vektor parametrov pomnoži ali deli s faktorjem  $\alpha$ , imenovanim dolžina koraka.

Za naslednjo populacijo je izmed vseh  $\lambda$  mutiranih in z dolžino koraka pomnoženih potomcev izbranih  $\mu$  članov, ki postanejo novi starši v naslednji populaciji. Celoten proces je omejen z maksimalnim številom iteracij oz. generacij ali pa se zaustavi, ko je celotna populacija znotraj območja s predhodno definiranim polmerom [3].

### 2.2.2.3 Diferenčna evolucija

DE je evlucijski algoritem, ki se uspešno uporablja za optimiranje [24]. Kot uporabna metoda se šteje predvsem zaradi njenih odlik, in sicer [16]:

- je EA, ki omogoča primerljive in/ali boljše rezultate v primerjavi s klasičnimi EA, kot so npr. GA in ES;
- parametri DE v splošnem ne zahtevajo finega nastavljanja,
- je enostavna za razumevanje in implementacijo.

Za algoritem DE velja, da je to t. i. *algoritem s stabilnim delovanjem*, pri katerem nove rešitve (osebki) ne tvorijo nove populacije, temveč jih preprosto dodajamo v obstoječo populacijo. Ta način pospešuje konvergenco, saj lahko pravkar izračunane kakovostne osebke takoj uporabimo za generiranje novih rešitev [35].

Podobnosti algoritma z ostalimi EA so očitne, vendar DE ne uporablja števil predstavljenih v binarni obliki kot GA in prav tako ne uporablja funkcije gostote verjetnosti za samoprilagajanje parametrov algoritma, kot je to primer pri ES [16]. Pri DE so osebki zapisani v obliki vektorjev, saj mehanizem diferenčne mutacije v postopku generiranja novih kandidatov za rešitve zahteva odštevanje vektorjev med seboj in njihovo množenje s skalarjem [38]. Razporeditev vektorjev je v glavnem določena s topografijo pripadajoče KF. Prenos informacije iz prostora kriterijev v optimizacijski proces omogoča algoritmu robustnost in večjo učinkovitost pri iskanju globalnega optimuma [42]. Pri DE morajo biti definirani le štirje parametri, in sicer [16]:

- velikost populacije  $NP$ ,
- število generacij  $g_{\max}$ ,

- faktor  $F$  na intervalu  $[0,1]$ , ki skalira razliko izračunano med naključno izbranimi staršema,
- konstanta križanja  $Cr$  na intervalu  $[0,1]$ , ki kontrolira vpliv starša na pripadajoče potomce.

Pristop deluje na ustvarjanju naključne začetne populacije  $NP$  osebkov oziroma vektorjev dimenzije  $D$ . *Trenutna populacija*  $\mathbf{P}_x$  je sestavljena iz vektorjev  $\mathbf{x}_{i,g}$ . Matematično jo zapišemo kot

$$\begin{aligned} \mathbf{P}_{x,g} &= [\mathbf{x}_{i,g}], \quad i = 0, \dots, NP-1, \quad g = 0, 1, \dots, g_{\max} \\ \mathbf{x}_{i,g} &= (x_{j,i,g}), \quad j = 0, 1, \dots, D-1 \end{aligned} \quad (2.31)$$

kjer  $g$  označuje generacijo, ki ji vektor pripada,  $i$  številko vektorja ter  $j$  parametre znotraj le-tega. Inicializirani populaciji pripada  $g=0$ . Po končani inicializaciji DE izvede mutacijo nad naključno izbranimi vektorji in nam na ta način generira *vmesno populacijo*  $\mathbf{P}_v$  z  $NP$  mutiranih vektorjev  $\mathbf{v}_{i,g}$ :

$$\begin{aligned} \mathbf{P}_{v,g} &= [\mathbf{v}_{i,g}], \quad i = 0, \dots, NP-1, \quad g = 0, 1, \dots, g_{\max} \\ \mathbf{v}_{i,g} &= (v_{j,i,g}), \quad j = 0, 1, \dots, D-1 \end{aligned} \quad (2.32)$$

Vsak vektor v trenutni populaciji  $\mathbf{P}_x$  je v nadaljevanju križan z njegovim mutantom iz  $\mathbf{P}_v$ , kar ustvari *začasno populacijo*  $\mathbf{P}_u$   $NP$  začasnih vektorjev  $\mathbf{u}_{i,g}$ :

$$\begin{aligned} \mathbf{P}_{u,g} &= [\mathbf{u}_{i,g}], \quad i = 0, \dots, NP-1, \quad g = 0, 1, \dots, g_{\max} \\ \mathbf{u}_{i,g} &= (u_{j,i,g}), \quad j = 0, 1, \dots, D-1 \end{aligned} \quad (2.33)$$

Ključna ideja DE je ravno generiranje začasnih osebkov [24], [43].

### **Inicializacija začetnega vektorja rešitev**

Preden se inicializira začetna populacija, morajo biti podane meje, znotraj katerih se lahko posamezni parametri spreminjajo. Te vrednosti so lahko podane v dveh vektorjih dimenzije  $D$ , npr.  $\mathbf{m}_s$  in  $\mathbf{m}_z$ , kjer indeksa  $s$  in  $z$  pomenita spodnjo in zgornjo mejo. Inicializirana začetna vrednost  $j$ -tega parametra v  $i$ -tem vektorju (prva generacija  $g=0$ ) je:

$$\begin{aligned} x_{j,i,0} &= \text{rand}_j(0,1)(m_{j,z} - m_{j,s}) + m_{j,s} \\ \mathbf{x}_{i,g} &= (x_{j,i,g}), \quad j = 0, 1, \dots, D-1 \end{aligned} \quad (2.34)$$

Generator števil  $\text{rand}_j(0,1)$  generira vrednosti z intervala  $[0,1)$ .


### Diferenčna mutacija

Po končani inicializaciji začetne populacije DE mutira populacijo in jo križa tako, da dobimo novo vmesno populacijo z  $NP$  vektorji. Za vsak posamezni vektor  $v$  v trenutni populaciji operator mutacije kreira en vmesni vektor. Mehanizem diferenčne mutacije generira vmesne vektorje tako, da dodaja skalirane razlike dveh naključno izbranih vektorjev v bazni (trenutni) populaciji k tretjemu naključno izbranemu vektorju iz bazne populacije. Tako je osnovna strategija DE kombiniranje treh naključno izbranih vektorjev iz trenutne populacije za izdelavo mutiranega oz. vmesnega vektorja  $v_i$ . Kot vidimo iz (2.35) razliko dveh vektorjev skupaj s skalirnim faktorjem (utežjo)  $F$ , dodamo tretjemu vektorju [24]:

$$\mathbf{v}_{i,g} = \mathbf{x}_{r_1,g} + F(\mathbf{x}_{r_2,g} - \mathbf{x}_{r_3,g}) \quad (2.35)$$

$F$  iz intervala  $[0;1]$  je pozitivno realno število, ki nadzira stopnjo razvoja populacije, indeksi  $r_1, r_2, r_3$  pa so naključno izbrani iz intervala  $[0, NP-1]$ . To pomeni, da smo za vsak opazovani vektor iz trenutne populacije naključno izbrali tri različne vektorje, pri tem pa noben od teh ni bil enak opazovanemu vektorju [44].

Na sliki 2.11 je predpostavljeno, da imamo opravka s funkcijo dveh spremenljivk tako, da imajo vektorji  $\mathbf{x}_{i,g}$  dimenzijo  $D = 2$  – vsebujejo po 2 parametra. Konture predstavljajo linije enake funkcijske vrednosti, osebki trenutne populacije pa so označeni s krogi. Algoritem obravnava vsakega izmed osebkov populacije in recimo, da smo v trenutni generaciji  $g$ , kjer je  $i$ -ti osebek  $\mathbf{x}_{i,g}$  predmet obravnave. Na izbrani osebek najprej deluje mehanizem diferenčne mutacije, ki iz populacije izbere tri med seboj različne osebkove  $\mathbf{x}_{r_1,g}, \mathbf{x}_{r_2,g}$ , in  $\mathbf{x}_{r_3,g}$  ter s pomočjo (2.35) generira mutirani oz. vmesni vektor  $\mathbf{v}_{i,g}$ . Z utežjo  $F$  pomnožena razlika dveh naključno izbranih vektorjev  $F(\mathbf{x}_{r_2,g} - \mathbf{x}_{r_3,g})$  diktira smer in velikost koraka pri iskanju novih rešitev. To razliko mehanizem diferenčne mutacije doda k tretjemu naključno izbranemu vektorju, ki služi kot bazna točka. Namen tega mehanizma je ključna ideja algoritma DE in to je samo-prilagajanje velikosti koraka skozi celoten evolucijski proces s pomočjo topologije problema. V začetnih generacijah je pri tem velikost koraka velika, saj so osebki med seboj precej oddaljeni, skozi generacije pa populacija konvergira k eni rešitvi, kar pomeni, da se raznolikost populacije zmanjšuje in posledično postaja tudi korak iskanja vse manjši. Naključnost tako smeri iskanja kot tudi izbire bazne točke, kateri dodajamo obteženo diferenco dveh vektorjev, v mnogih primerih omogoča odkrivanje globalnega optimuma, vendar na račun počasnejše konvergence.



Slika 2.11: Grafični prikaz diferenčne mutacije v prostoru dveh spremenljivk

Pri generiranju novih potencialnih rešitev, včasih zaradi prevelikega koraka, novonastali vmesni vektor pade iz prostora dovoljenih rešitev. V tem primeru obstajata dva pogosta pristopa, kako rešiti problem, in sicer:

- parameter v vektorju, ki je padel iz prostora dovoljenih rešitev naključno generiramo na intervalu med spodnjo in zgornjo vrednostjo  $j$ -tega parametra,
- parameter, ki ni v skladu z omejitvami, nadomestimo z najbližjo mejno vrednostjo [45].

Prednost obeh načinov je dejstvo, da ne zahtevajo potrebe po ponovitvi postopka za izdelavo novega kandidata, kar pa je seveda tudi ena od možnosti.

### Križanje

Za dopolnitev strategije diferenčne mutacije, DE prav tako izvede križanje (slika 2.12) ter ustvari začasni vektor  $\mathbf{u}_{i,g}$ , ki je potomec dveh staršev, in sicer mutiranega vektorja  $\mathbf{v}_{i,g}$  in obravnavanega vektorja iz bazne populacije  $\mathbf{x}_{i,g}$ . Vsak parameter iz mutiranega vektorja  $\mathbf{v}_{i,g}$  je sprejet v začasni vektor  $\mathbf{u}_{i,g}$  z verjetnostjo  $Cr$  [24].

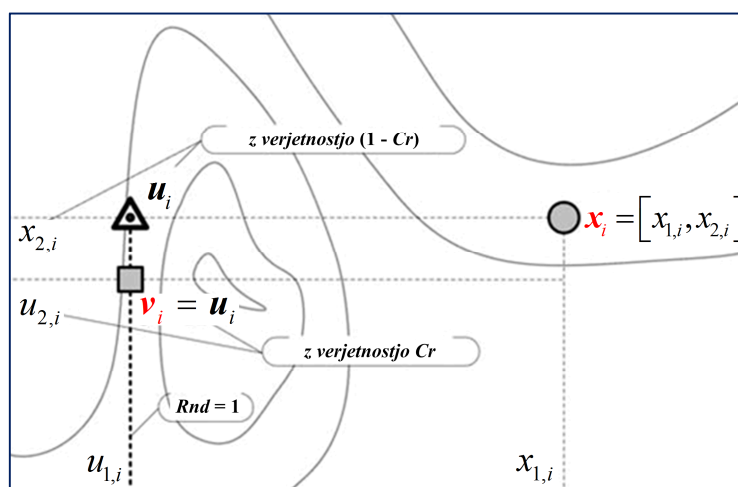
$$\mathbf{u}_{j,i,g} = \begin{cases} \mathbf{v}_{j,i,g} & \text{rand}_j(0,1) \leq Cr \quad \forall j = j_{rand} \\ \mathbf{x}_{j,i,g} & \text{sicer} \end{cases} \quad (2.36)$$

$$\mathbf{u}_{i,g} = (\mathbf{u}_{j,i,g}), j = 0, 1, \dots, D-1$$

$Cr$  izberemo z intervala  $[0;1]$ , predstavlja pa verjetnost križanja oz. verjetnost, da bo na določeno pozicijo  $j$  v začasnem vektorju  $\mathbf{u}_{i,g}$  kopiran parameter iz mutiranega vektorja  $\mathbf{v}_{i,g}$ . S pomočjo (2.36) preprosto ugotovimo, kateri vir,  $\mathbf{x}_{i,g}$  ali  $\mathbf{v}_{i,g}$  prispeva dani parameter začasnemu vektorju  $\mathbf{u}_{i,g}$ , in sicer tako, da verjetnost križanja  $Cr$  primerjamo z izhodom generatorja naključnih števil  $\text{rand}_j(0,1)$ . Če je naključno število manjše ali enako



vrednosti  $Cr$ , bo parameter kopiran iz mutiranega vektorja  $\mathbf{v}_{i,g}$ , sicer pa iz baznega vektorja  $\mathbf{x}_{i,g}$ . Kljub izbiri konstante križanja, ki ima vrednost blizu 1, se lahko zgodi, da bo izhod iz generatorja naključnih števil v vsakem poskusu  $j=0,1,\dots,D-1$  večji od vrednosti  $Cr$ , to pa pomeni, da bo v tem primeru začasni vektor  $\mathbf{u}_{i,g}$  direktna kopija baznega vektorja  $\mathbf{x}_{i,g}$ . Z namenom, da zagotovimo, da bo ne glede na konstanto križanja  $Cr$  vedno vsaj en parameter vzet iz mutiranega vektorja  $\mathbf{v}_{i,g}$ , je uporabljeno naključno število  $rand$  generirano na intervalu od 1 do  $D$ . Parameter na tej naključno izbrani poziciji v mutiranem vektorju  $\mathbf{v}_{i,g}$  bo ne glede na  $Cr$  kopiran v začasni vektor  $\mathbf{u}_{i,g}$ , kar zagotavlja, da začasni vektor  $\mathbf{u}_{i,g}$  ne bo nikoli direktna kopija baznega vektorja  $\mathbf{x}_{i,g}$ . Zaradi tega dodatka, verjetnost križanja  $Cr$  samo aproksimira dejansko verjetnost, da bo začasni vektor podedovan iz mutiranega vektorja.




Slika 2.12: Križanje vmesnega (mutiranega)  $\mathbf{v}_{i,g}$  in baznega vektorja  $\mathbf{x}_{i,g}$  v postopku generiranja začasnega vektorja  $\mathbf{u}_{i,g}$

### Selekcija

Mehanizma diferenčne mutacije in križanja sledi selekcija. Mehanizem selekcije primerja potomca oz. začasni vektor  $\mathbf{u}_{i,g}$  s staršem oz. baznim vektorjem  $\mathbf{x}_{i,g}$ . Če ima potomec  $\mathbf{u}_{i,g}$  boljšo ali enako vrednost KF, potem le-ta v populaciji nadomesti starša  $\mathbf{x}_{i,g}$ , sicer starš obdrži svojo pozicijo:

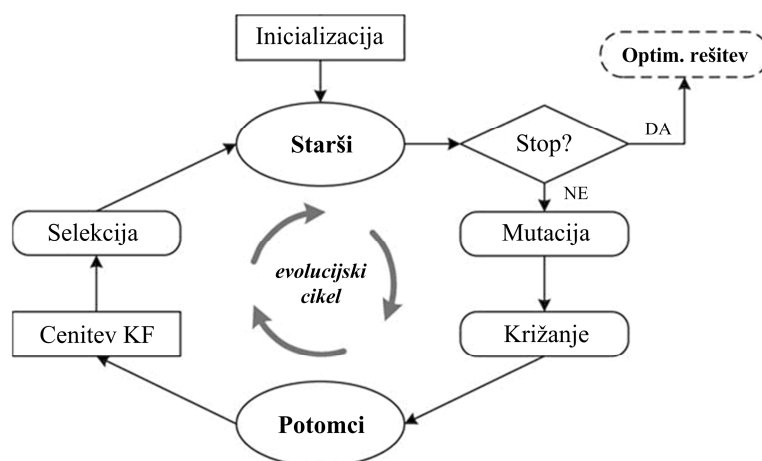
$$\mathbf{x}_{i,g+1} = \begin{cases} \mathbf{u}_{i,g}, & \text{če } f(\mathbf{u}_{i,g}) \leq f(\mathbf{x}_{i,g}) \\ \mathbf{x}_{i,g}, & \text{sicer} \end{cases} \quad (2.37)$$

Opisani način selekcije kvaliteto populacije kontinuirano izboljšuje ali pa jo vsaj ohranja. Uporabljena selekcija se imenuje elitistična selekcija ali *elitizem*, njeno delovanje pa je predstavljeno na sliki 2.13.



Slika 2.13: Elitistična selekcija


Ko je enkrat nova populacija  $g+1$  generirana, se proces mutacije, križanja in selekcije ponovi (slika 2.14). Ponavljanje se izvaja zaporedoma, vse dokler ne dosežemo zaustavitvenega kriterija [24], [44].



Slika 2.14: Shema delovanja DE algoritma

#### 2.2.2.4 Primerjava predstavljenih stohastičnih metod na analitično zapisanih funkcijah

Za primerjavo uspešnosti algoritmov obstaja vrsta standardnih testnih funkcij [24], med katerimi smo za testiranje izbrali dve, in sicer testno funkcijo *Rastrigin* (slika 2.15 a) ter *Rosenbrock* (slika 2.15 b).

Slika 2.15: Testni funkciji: a) *Rastrigin* in b) *Rosenbrock*


Prikazana testna funkcija *Rastrigin* za dve neodvisni spremenljivki je zvezna večmodalna funkcija z velikim številom lokalnih optimumov in definirana kot  $f(\mathbf{x}) = 20 + x_1^2 + x_2^2 - 10(\cos 2\pi x_1 + \cos 2\pi x_2)$ . Njen globalni optimum leži v točki  $\mathbf{x}^*(0,0)$ , kjer zavzame funkcijsko vrednost, ki je enaka 0. Prostor preiskovanja je omejen na  $m_s = -5,12$  in  $m_z = 5,12$ . Testna funkcija *Rosenbrock* je zvezna in enomodalna kvadratna funkcija dveh spremenljivk  $f(\mathbf{x}) = 100(x_2 - x_1^2)^2 + (x_1 - 1)^2$  z minimumom v točki  $\mathbf{x}^*(1,1)$ , kjer je funkcijska vrednost prav tako enaka 0. Dejansko je za samo optimizacijo uporabljen kvadratni koren pri izračunu njenih funkcijskih vrednosti, velikost iskalnega prostora pa je mogoče razbrati s slike.

V nadaljevanju je narejena primerjava rezultatov optimizacije v grafični obliki za obe testni funkciji. Vsi rezultati veljajo za velikost populacije  $NP = 20$  ter naslednje krmilne parametre posameznih algoritmov, in sicer GA: verjetnost križanja 0,8; verjetnost mutacije 0,01; DE:  $F = 0,5$ ;  $Cr = 0,8$ ;  $st. = 7$  (DE/rand/1/bin) in ES:  $\alpha = 1,15$ ;  $\mu = 12$ ;  $\rho = 10$ ;  $\lambda = 20$ . Na vsakem od grafov na sliki 2.16 je izrisana najmanjša in največja funkcijska vrednost pripadajočih osebkov populacije ter povprečna vrednost celotne populacije, in sicer za vsako generacijo posebej [46]. Grafi veljajo za nerotirane in "neshiftane" testne funkcije ter v primeru *Rastrigin* za testno funkcijo z optimumom v središču prostora parametrov.

V primeru testne funkcije *Rastrigin* z GA (slika 2.16 a) vidimo, da dosežemo konvergenco po približno 120-ih generacijah, pri temu pa je raznolikost populacije še vedno velika, saj tako srednja kot tudi največja vrednost KF precej odstopa od dosežene minimalne vrednosti. Srednja funkcijska vrednost celotne populacije (črna linija) sicer pada proti najdenemu optimumu, doseže pa jo po večjem številu generacij, kot je na sliki prikazano. Za algoritem DE (slika 2.16 b) se v tem primeru izkaže, da konvergira hitreje, enako število generacij kot na sliki 2.16 a pa je prikazano zaradi medsebojne primerljivosti algoritmov. Podobno hitro konvergira tudi algoritem ES (slika 2.16 c).

Pri GA lahko vidimo tudi, da se osebek, ki je do nekega trenutka evolucije imel najboljšo funkcijsko vrednost, ohranja skozi generacije, vse dokler algoritem ne najde boljšega, medtem ko slabši osebki, ki nastajajo znotraj genetskih operacij, lahko vstopajo v

naslednje generacije. Pri DE imamo opravka vedno z dvema populacijama, in sicer bazno ter začasno. Med osebki teh dveh populacij izvajamo tekmovalno selekcijo, kjer osebki iz začasne populacije zamenjujejo osebkke bazne populacije le v primeru, če so boljši od njih. Kot je vidno na sliki 2.16 b, je to vzrok, da se v kasnejših generacijah pojavljajo samo osebki, katerih funkcijske vrednosti so boljše ali vsaj enake predhodnikom, in sicer tako za najboljše kot tudi najslabše osebkke. Nasprotno velja za ES, kjer algoritem najboljše osebkke iz generacije v generacijo lahko tudi izgubi.



Slika 2.16: Rezultati za posamezne algoritme – a) GA, b) DE in c) ES za *Rastrigin* (levo) ter d) GA, e) DE in f) ES za testno funkcijo *Rosenbrock* (desno)

Podobne rezultate dobimo tudi pri iskanju optimuma *Rosenbrock* testne funkcije (desna polovica slike 2.16). Le-ta ima en sam optimum, kateremu so se vsi trije algoritmi približali v manjšem številu generacij.

Bistvena razlika med GA in DE pri tvorjenju novih in boljših rešitev je ta, da GA temelji na križanju, medtem ko DE temelji na mutacijah. Tudi pri ES igrajo mutacije ključno

vlogo. Razlike in podobnosti so vidne na sliki 2.16, pri tem se moramo zavedati, da vsi trije algoritmi niso prišli enako blizu optimumu posamezne KF, oz. da rešitve niso enako kvalitetne. Daleč najboljši pri tem je bil algoritem DE, vendar je v primeru Rosenbrock testne funkcije potreboval veliko število cenitev KF ( $n_{\text{feval}}$ ). Najboljši približek optimuma ter število potrebnih cenitev KF za posamezni algoritem je podano v tabeli 2.1.

Tabela 2.1: Primerjava algoritmov za a) Rastrigin in b) Rosenbrock funkcijo

Slika 2.16:		$f(\mathbf{x})$	$n_{\text{feval}}$	$x_1$	$x_2$
GA	a)	3,39E-2	2420	1,31E-2	-1,95E-4
	d)	2,73E-2	1380	1,0053	1,0258
DE	b)	0	2060	0	0
	e)	0	4000	1	1
ES	c)	1,59E-8	2980	-2,66E-6	-2,66E-6
	f)	9,242E-3	1236	0,9909	0,9822

Na osnovi rezultatov optimizacije testnih funkcij sklepamo, da ima izmed testiranih algoritmov DE najstabilnejšo konvergenco. DE glede na število cenitev KF poišče najbolj kvalitetno rešitev (točno vrednost in lokacijo globalnega optimuma) v primerjavi z ostalima dvema algoritmoma. Ta informacija je pomembna pri odločanju, kateri optimizacijski algoritem uporabiti takrat, ko le-tega želimo aplicirati na kakšnem optimizacijskem problemu s področja tehnike.

Kvaliteta rešitve in predvsem hitrost konvergence je pomembna v primerih, kjer ocenjujemo vrednost KF s pomočjo MKE izračunov [19]. Čas, ki je potreben za en izračun z MKE je lahko relativno dolg, kar pomeni, da je lahko trajanje optimizacijskega postopka zelo dolgo preden dosežemo konvergenco.



### 3. RAZŠIRITVE ALGORITMA DIFERENČNE EVOLUCIJE

Algoritem DE se je na številnih enokriterijskih optimizacijskih problemih izkazal kot uspešen EA, zato ga je smiselno razširiti in uporabljati tudi za reševanje optimizacijskih problemov z več kriteriji. Kot je že v uvodu zapisano, je DE glede na lastne izkušnje kot tudi glede na rezultate objav med uspešnejšimi in robustnejšimi optimizacijskimi tehnikami. Zaradi tega je bil v okviru disertacije izbran kot primarna optimizacijska tehnika. Njegova prednost je v mehanizmu mutacije, kjer obstoječa distribucija rešitev v prostoru preiskovanja določa velikost koraka in smer iskanja za vsak osebek posebej [48]. DE tako za upravljanje mehanizma mutacije tvori mutirane osebkke, z vzorčenjem iz skalirane razlike naključno izbranih staršev v populaciji [49]. S tem skuša implicitno tvoriti idealno distribucijo za obravnavano populacijo [50] in ta lastnost je ena od glavnih prednosti DE algoritma.

Algoritem DE izvaja križanje tako, da omogoča osebkku uvoz parametrov iz mutiranih vektorjev. To opisuje potencialni hiper-pravokotnik (z baznim in mutiranim vektorjem v nasprotnih kotih), na katerih novi osebki tudi leži. Stranice tega hiper-pravokotnika so v smeri osi koordinatnega sistema, kar naredi korake iskanja s križanjem ortogonalne smerem koordinat funkcije. Ta operacija je nadzorovana s konstantno križanja  $Cr$ , ki določa pričakovano število parametrov, ki jih kopiramo iz mutiranih vektorjev. V osnovi  $Cr$  določa pričakovano dimenzijo podprostora, v katerem bo potomec ležal [51].

Zaradi dobrih lastnosti algoritma DE in možnosti enostavne modifikacije, se dandanes sam algoritem pogosto povezuje z drugimi tehnikami. Osnovni namen takšnega početja je doseganje čimbolj učinkovitega optimizacijskega procesa. DE skupaj z izbranimi dopolnitvami in razširitvami je podrobneje predstavljen v nadaljevanju.

### 3.1 Večkriterijska optimizacija

V praksi se pogosto srečujemo z zahtevo po sočasnem optimiranju po več različnih kriterijih, ki pa so v večini primerov med seboj konfliktni, kar z drugimi besedami povedano pomeni, da izboljšanje rešitve po enem kriteriju povzroči poslabšanje po drugem kriteriju. V tem primeru nimamo več opravka z eno samo optimalno rešitvijo, temveč z množico optimalnih rešitev, imenovano *Pareto optimalna fronta*. Če ne poznamo informacije, ki bi nam podajala pomembnost vsakega posameznega kriterija, si želimo, da bi poznali vse rešitve s Pareto optimalne fronte in bi si šele nato izbrali eno izmed njih [35].

Pri večkriterijski optimizaciji poskušamo simultano minimizirati  $k$  individualnih KF. Njen cilj je poiskati vektor:

$$\mathbf{x} = (x_0, x_1, \dots, x_{D-1})^T, \mathbf{x} \in \mathfrak{R}^D \quad (3.1)$$

ki bo minimiziral vektorsko funkcijo  $\mathbf{f}(\mathbf{x})$  oz.  $k$  KF

$$\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x})] \quad (3.2)$$

$\mathfrak{R}^D$  je  $D$ -dimenzijski prostor realnih števil. Poseben primer rešitve problema je primer, kjer en sam vektor  $\mathbf{x}$  sočasno minimizira vsako izmed  $k$  KF. Rešitev v tem primeru imenujemo globalni optimum. V praksi pa si, kot je zgoraj omenjeno, kriteriji običajno nasprotujejo, kar pomeni, da optimumi vseh  $k$  KF ne ležijo pri isti rešitvi  $\mathbf{x}$  [24]. Primer nasprotujočih si kriterijev sta kvaliteta in cena. V takšnem primeru ne moremo definirati ene same rešitve problema.

Zaradi narave praktičnih problemov je večkriterijska optimizacija zelo pogosta, predvsem pri tehniških aplikacijah. Kot že ime narekuje, večkriterijska optimizacija vključuje več kriterijev, ki bi naj bili sočasno optimirani [48].


Glavna razlika med več in enokriterijsko optimizacijo je ta, da pri večkriterijski optimizaciji običajno nimamo ene rešitve, temveč množico le-teh, ki pa so vse enako dobre [52]. Pri enokriterijski optimizaciji je prostor kriterijev množica realnih števil  $\mathfrak{R}$ , ki je z relacijo  $\leq$  popolnoma urejena [53]. Tako za poljubni rešitvi enokriterijskega optimizacijskega problema  $\mathbf{x}$  in  $\mathbf{y}$  velja natanko ena od trditev:

- rešitev  $\mathbf{x}$  je boljša od  $\mathbf{y}$ ,
- rešitev  $\mathbf{y}$  je boljša od  $\mathbf{x}$  in
- rešitvi sta enakovredni.



Pri večkriterijski optimizaciji je prostor kriterijev večdimenzionalen, zato za relacijo  $\mathfrak{R}^D$  ne velja popolna urejenost, temveč le delna. Dve rešitvi sta tako pogosto neprimerljivi, zato si večina večkriterijskih algoritmov pri iskanju rešitve pomaga s konceptom *dominantnosti*. Ena rešitev večkriterijskega problema  $\mathbf{x}$  dominira rešitev  $\mathbf{y}$ , če sta izpolnjeni naslednji dve zahtevi:

- rešitev  $\mathbf{x}$  ni slabša od rešitve  $\mathbf{y}$  po nobenem od kriterijev  $\mathbf{f}$ ,
- rešitev  $\mathbf{x}$  je boljša od rešitve  $\mathbf{y}$  vsaj po enem kriteriju, po drugem pa mora biti vsaj enakovredna [35].



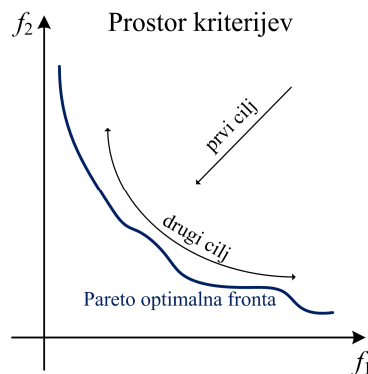
Slika 3.1: Prikaz koncepta dominantnosti na primeru večkriterijske funkcije  $\mathbf{f}$

Na sliki 3.1 je prikazan primer večkriterijske funkcije  $\mathbf{f}$ , ki prostor spremenljivk preslika v prostor kriterijev. V primeru minimizacije po obeh kriterijih za rešitev  $\mathbf{a}$  velja, da dominira rešitvi  $\mathbf{b}$  in  $\mathbf{c}$ , saj je od rešitve  $\mathbf{b}$  boljša po obeh kriterijih, od rešitve  $\mathbf{c}$  pa je boljša vsaj v enem kriteriju, medtem ko je po drugem enakovredna. Z rešitvijo  $\mathbf{d}$  ni primerljiva, saj je v enem kriteriju boljša, po drugem slabša, medtem ko rešitev  $\mathbf{e}$  dominira rešitev  $\mathbf{a}$ , saj  $\mathbf{e}$  ni slabša od  $\mathbf{a}$  po nobenem od kriterijev.

Rešitev večkriterijskega problema je množica nedominiranih rešitev (imenovanih tudi *nedominirana fronta*), ki leži v prostoru dopustnih rešitev (množica rešitev  $\mathfrak{M}$ ). Množica nedominiranih rešitev celotnega prostora dopustnih rešitev se imenuje *Pareto optimalna fronta*, njeni elementi pa *Pareto optimalne rešitve*. V primeru s slike 3.1 sta to rešitvi  $\mathbf{d}$  in  $\mathbf{e}$ . Dejansko je to množica alternativnih rešitev, katere obravnavamo kot enakovredne, zato težimo k temu, da je ta množica Pareto optimalnih rešitev čim večja. Prav tako si pri izbiranju preferirane rešitve iz te množice želimo, da so le-te čim bolj enakomerno razporejene po Pareto fronti oz. robu. Pri iskanju rešitev večkriterijskega problema imamo tako pred seboj dva cilja (slika 3.2), in sicer [35]:

- poiskati rešitve, ki so čim bližje dejanski Pareto optimalni fronti in

- poiskati rešitve, ki so čim bolj enakomerno razporejene vzdolž Pareto optimalne fronte.



Slika 3.2: Cilja večkriterijske optimizacije

Zadovoljitev teh dveh ciljev je izziv za vse algoritme namenjene reševanju večkriterijskih optimizacijskih problemov, koncept Pareto dominantnosti pa omogoča približevanje obema ciljema. Za opis koncepta optimalnosti je v nadaljevanju predstavljeno tudi nekaj definicij [48].

### 3.1.1 Pareto dominantnost

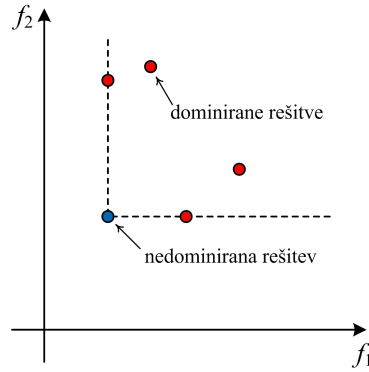
Potencialna rešitev večkriterijskega optimizacijskega problema  $\mathbf{x} = (x_0, x_1, \dots, x_{D-1})$  dominira rešitev  $\mathbf{y} = (y_0, y_1, \dots, y_{D-1}) \in \mathfrak{X}^D$ , če sta izpolnjeni naslednji dve zahtevi [35]:

- rešitev  $\mathbf{x}$  ni slabša od  $\mathbf{y}$  po nobenem od kriterijev:  $\forall i \in (1, \dots, k), f_i(\mathbf{x}) \leq f_i(\mathbf{y})$  in
- rešitev  $\mathbf{x}$  je boljša od  $\mathbf{y}$  po vsaj enem kriteriju:  $\exists i \in (1, \dots, k), f_i(\mathbf{x}) < f_i(\mathbf{y})$ .

Definicija pravi, da ena rešitev dominira drugo samo, če je ta striktno boljša v vsaj enem kriteriju in hkrati ni slabša v nobenem od preostalih kriterijev (slika 3.3) [52]. V primeru, ko primerjamo dve rešitvi, npr.  $\mathbf{x}$  in  $\mathbf{y}$ , so na voljo tri možnosti, in sicer:

- $\mathbf{x}$  dominira  $\mathbf{y}$ ,
- $\mathbf{y}$  dominira  $\mathbf{x}$ ,
- $\mathbf{x}$  in  $\mathbf{y}$  sta nedominirani rešitvi.

Dominacijo rešitve oz. vektorja  $\mathbf{x}$  nad vektorjem  $\mathbf{y}$  simbolično zapišemo kot  $\mathbf{x} \prec \mathbf{y}$ .



Slika 3.3: Dominirane in nedominirane rešitve v prostoru dveh kriterijev

### 3.1.2 Pareto optimalnost

Vektor  $\mathbf{x} \in \mathcal{M} \subset \mathcal{R}^D$  je nedominiran na področju  $\mathcal{M}$ , če tam ne obstaja takšen  $\mathbf{x}' \in \mathcal{M}$ , da velja  $f(\mathbf{x}') \prec f(\mathbf{x})$ . Vektor  $\mathbf{x}^* \in \mathcal{F} \subset \mathcal{R}^D$  ( $\mathcal{F}$  je *prostor dopustnih rešitev*) je Pareto optimalen, če je nedominiran na področju  $\mathcal{F}$ . Z drugimi besedami, vektor  $\mathbf{x}^*$  je Pareto optimalen, če ne obstaja druga dopustna rešitev, ki bi znižala vrednost enega kriterija, ne da bi povzročila hkratno povišanje v vsaj enem od drugih kriterijev. V prostoru spremenljivk obstaja več nedominiranih rešitev in množico takšnih rešitev imenujemo Pareto optimalna množica. Pareto optimalna množica  $\mathcal{P}^*$  je definirana kot [48]:

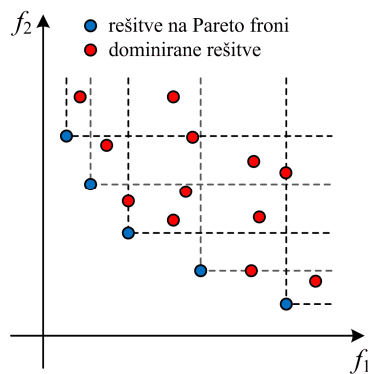
$$\mathcal{P}^* = \{\mathbf{x} \in \mathcal{F} \mid \mathbf{x} \text{ je Pareto optimalen}\} \quad (3.3)$$

### 3.1.3 Pareto fronta

Ko so vse nedominirane rešitve, torej Pareto optimalna množica preslikana v prostor kriterijev, je Pareto optimalna fronta definirana kot [48], [52]:

$$\mathcal{PF}^* := \{f(\mathbf{x}) = [f_1(\mathbf{x}), \dots, f_k(\mathbf{x})] \mid \mathbf{x} \in \mathcal{P}^*\} \quad (3.4)$$

Na sliki 3.4 je prikazana Pareto optimalna fronta v prostoru dveh kriterijev.



Slika 3.4: Pareto optimalna fronta

### 3.2 Algoritem diferenčne evolucije za večkriterijsko optimizacijo (DEMO)

Pri implementaciji rešitve za reševanje večkriterijskih problemov v algoritmu DE, predstavlja največjo težavo mehanizem selekcije, ki primerja potomca in starša [35]. Namreč, primerjava dveh rešitev pri enokriterijski optimizaciji je enoumna, saj je lahko ena rešitev, boljša, slabša ali enakovredna drugi rešitvi. Izbere se seveda tisto rešitev, ki bolje zadovolji kriterij. Nasprotno, v primeru večkriterijske funkcije lahko ena rešitev bolje zadovolji en kriterij, druga pa drug kriterij tako, da odločitev, katera rešitev ostaja v populaciji, ni več tako preprosta. Da bi lahko uporabili algoritem DE za reševanje večkriterijskih problemov, je potrebno izvirni algoritem preoblikovati, saj se rešitev problema z več kriteriji ne sestoji iz ene same rešitve kot pri enokriterijski optimizaciji temveč iz množice le-teh. Pri večkriterijski optimizaciji težimo k temu, da najdemo množico med seboj različnih rešitev, t. i. Pareto optimalno množico [48], oz. da najdemo več Pareto optimalnih rešitev v enem samem zagonu optimizacijskega procesa [54]. Pri preoblikovanju klasičnega algoritma DE v različico za reševanje večkriterijskih problemov moramo odgovoriti na dve vprašanji, in sicer [48]:

1. Kako vzdrževati raznolikost populacije?
2. Kako izbirati in/ali obdržati dobre rešitve oz. kako izvajati elitizem?

Avtorja [45], [55] sta vpeljala nov pristop za večkriterijsko optimizacijo, imenovan Diferenčna evolucija za večkriterijsko optimizacijo (anlg. *Differential Evolution for Multicriterion Optimization* – DEMO) in ta algoritem je le eden v množici tovrstnih algoritmov. Čeprav je algoritem podoben ostalim algoritmom za reševanje večkriterijskih optimizacijskih problemov na osnovi algoritma DE, se implementacija DE

razlikuje glede na ostale pristope in tako DEMO predstavlja nov pristop k večkriterijski optimizaciji. Algoritem DEMO vključuje dva ključna mehanizma:

- Prvi mehanizem in jedro algoritma je *Elitistična selekcija*, ki takoj nadomešča starša s potomcem, če ga potomec dominira. Novo nastali kandidati, ki vstopijo v populacijo bodisi z zamenjavo (ko ena rešitev dominira drugo) bodisi z dodajanjem (ko sta rešitvi med seboj nedominirani), takoj sodelujejo pri kreiranju novih kandidatov. Elitistična selekcija pri tem pomaga doseči prvi cilj večkriterijske optimizacije - konvergenco k pravi Pareto optimalni fronti.
- Drugi mehanizem je nedominirano rangiranje, ki pomaga doseči naslednji cilj večkriterijske optimizacije – iskanje kolikor je možno raznolikih nedominiranih rešitev.

Algoritem DEMO vsako generacijo ponavlja naslednje korake. Najprej iz vsakega osebka v populaciji generira potomca po postopku na sliki 3.5. Potomca dalje ovrednoti in ga primerja z njegovim staršem. Če starš dominira potomca, potem mehanizem selekcije potomca zavrže. V primeru, ko sta starš in potomec nedominirana ali v primeru, da potomec dominira starša, pa ga doda v populacijo. To primerjavo naredimo za vseh  $NP$  staršev v populaciji [45] in na ta način se velikost populacije stalno povečuje. Na koncu te operacije imamo skupno velikost populacije med  $NP$  in  $2NP$ , zato algoritem izvede nedominirano sortiranje, ki pa je kombinirano z uporabo metrike nakopičenosti z namenom klestenja (angl. *Truncation*) populacije oz. vzdrževanja fiksnega števila ( $NP$  osebkov) populacije v vsaki generaciji [48]. Uporaba nedominiranega sortiranja in metrike nakopičenosti nad razširjeno populacijo omogoča enakomerno razporeditev rešitev vzdolž Pareto optimalne fronte. Oklestena populacija je nato pripravljena na novi korak algoritma.

#### DEMO

1. Naključno generiraj in ovrednoti začetno populacijo rešitev  $P_x$ .
2. Do izpolnitve zaustavitvenega kriterija, ponavljaj:
  - 2.1 Za vsak osebek  $x_i$  ( $i = 1, \dots, NP$ ) iz  $P_x$  ponavljaj:
    - (a) Iz starša  $x_i$  generiraj potomca oz. kandidata  $u_i$ .
    - (b) Kandidata ovrednoti.
    - (c) Če kandidat dominira starša, ga zamenja v populaciji  
Če je kandidat dominiran od starša, ga zavrzi.  
Sicer kandidata dodaj v populacijo.
  - 2.2 Če ima populacija več osebkov kot je  $NP$ , jo zmanjšaj na velikost  $NP$ .
  - 2.3 Naključno oštevilči osebkove iz  $P_x$ .

#### Generiranje kandidata

Vhod: Osebek  $x_i$

1. Naključno izberi osebkove  $x_{r_1}$ ,  $x_{r_2}$  in  $x_{r_3}$  iz  $P_x$  tako, da so  $i$ ,  $r_1$ ,  $r_2$  in  $r_3$  paroma različni.
2. Izračunaj vmesno rešitev  $v_i = x_{r_1} + F(x_{r_2} - x_{r_3})$ , kjer je  $F$  faktor skaliranja.
3. Izvedi križanje vmesne rešitve in starša.

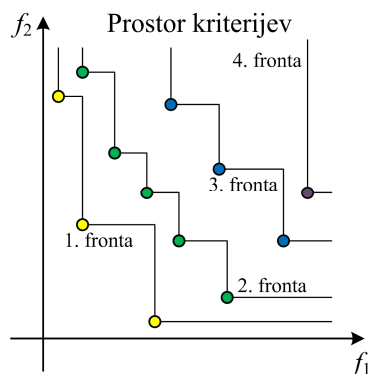
Izhod: Kandidat  $u_i$

Slika 3.5: Algoritem DEMO in generiranje kandidata za rešitev po shemi DE/rand/1/bin

## 3.2.1 Elementi redukcije velikosti in vzdrževanja raznolikosti populacije

### 3.2.1.1 Nedominirano sortiranje (Pareto rangiranje)

Eden od mnogih popularnih mehanizmov, ki se uporabljajo za izbiro najboljših osebkov, je nedominirano sortiranje. Ta pristop temelji na t. i. Pareto rangiranju [48]. Princip delovanja podrobneje navaja vir [57], rezultat rangiranja pa je prikazan na sliki 3.6.



Slika 3.6: Proces rangiranja pri pristopu nedominiranega sortiranja

Na začetku mehanizem nedominiranega sortiranja v celotni populaciji poišče rešitve, ki so nedominirane. Le-te v naslednjem koraku razvrsti v kategorijo z rangom 1 (prva fronta). V naslednji fazi nedominirane rešitve izvzame iz obravnave, v preostali množici pa ponovno poišče nedominirane rešitve, ki v tem koraku pripadajo drugi fronti. Postopek se izvaja vse dokler vsaki rešitvi ni določena pripadnost k eni od front. Osebkki v prvih frontah so seveda bolj preferirani pri izbiri v nadaljnjih postopkih.

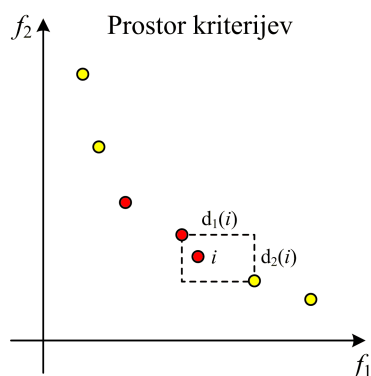
### 3.2.1.2 Metrika nakopičenosti

Vzdrževanje raznolikosti populacije lahko izvajamo na osnovi mehanizmov, ki ocenjuje bližino osebkov v populaciji. Da dosežemo zadostno raznolikost med nedominiranimi rešitvami, moramo izbrati kvalitetno mero za oceno nakopičenosti okoli vsake posamezne nedominirane rešitve [54]. Dva najbolj pogosta načina za določitev ocene nakopičenosti sta metrika nakopičenosti (angl. *Crowding distance*) [35], [36], [48] in delitev ocene kvalitete osebka (angl. *Fitness sharing*) [58].

Metrika nakopičenosti nam podaja informacijo, kako na gosto so razporejeni sosedi opazovanega osebka, in sicer gledano v prostoru kriterijev. Do te mere pridemo dejansko z ocenjevanjem obsega pravokotnika, kateremu diagonali oz. diagonalna vozlišča ležijo na najbližjih sosednjih osebkih (slika 3.7) [47], [48]. Mera nakopičenosti je v osnovi vsota posameznih razdalj med sosednjima osebkom, izračuna pa se s pomočjo naslednjega izraza [56], [57]:


$$c_{x_i} = \sum_{j=1}^k \frac{(f_{j,i+1} - f_{j,i-1})}{(f_{j,\max} - f_{j,\min})} \quad (3.5)$$

kjer  $f_j$  ustreza  $j$ -ti KF in  $k$  ustreza številu KF.



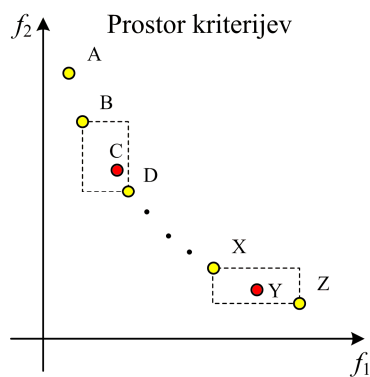
Slika 3.7: Računanje metrike nakopičenosti

Metoda za oceno nakopičenosti se uporabi na rešitvah, ki so med seboj nedominirane, kot je prikazano na sliki 3.8. Izvajamo pa jo takrat, ko populacija presega dovoljeno velikost in jo je potrebno zmanjšati. V tem primeru je potrebno identificirati osebke v najbolj nakopičenem področju (modri krogec) in jih eliminirati toliko, da dosežemo ustrezno velikost populacije [54].



Slika 3.8: Pareto optimalna množica, kjer sta označeni rešitvi z večjo (rdeča) in manjšo (modra) metriko nakopičenosti

Opisana mera stopnje nakopičenosti pa včasih ne more natančno podati informacije o stopnji nakopičenosti osebkov, kot je to prikazano na sliki 3.9:



Slika 3.9: Primer Pareto optimalne množice z razporeditvijo osebkov, pri kateri je informacija o nakopičenosti zavajajoča

Na sliki 3.9 vidimo, da so rešitve okoli točke C bolj nakopičene kot okoli točke Y, medtem ko je metrika nakopičenosti celo malo večja za rešitev C kot za rešitev Y (večji obseg pa pomeni manjšo stopnjo nakopičenosti), saj je rešitev B zelo oddaljena od rešitve C. Rešitev B v tem primeru negativno vpliva na metriko nakopičenosti in na točnost informacije, katero le-ta nosi.

Glede na [59] je za vzdrževanje raznolikosti populacije potrebno nedominirano sortiranje uporabljati tudi v kombinaciji s tehniko *Niching*. Ena od rešitev opisanega problema pa je izračun harmonične povprečne razdalje, ki pa je predstavljen v [54]. Alternativen pristop je tudi algoritem *Adaptive grid* [60] – postopek za določanje nakopičenosti, ki temelji na ponavljajoči delitvi  $d$ -dimenzijskega prostora.

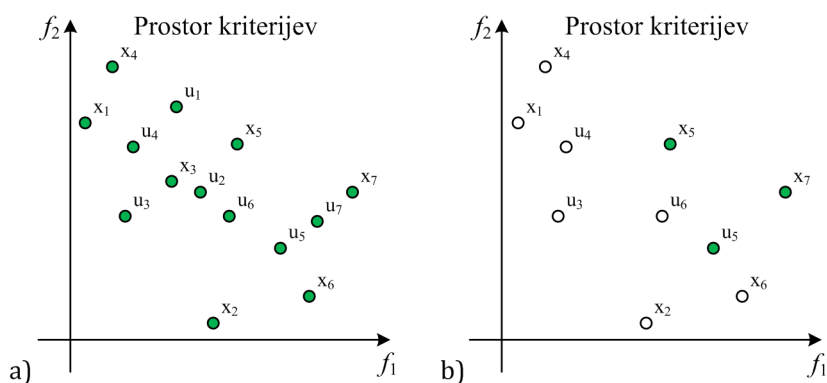
### 3.2.1.3 Klestenje populacije

Klestenje populacije izvajamo s pomočjo mehanizmov Pareto rangiranja in metrike nakopičenosti [58]. Rešitev A je tako izbrana pred rešitvijo B, če:

- ima rešitev A boljši rang kot rešitev B,
- imata rešitvi enak rang, vendar ima rešitev A boljšo stopnjo nakopičenosti (manjša vrednost metrike nakopičenosti).

Kako to zgleda v praksi, je prikazano na naslednji sliki.



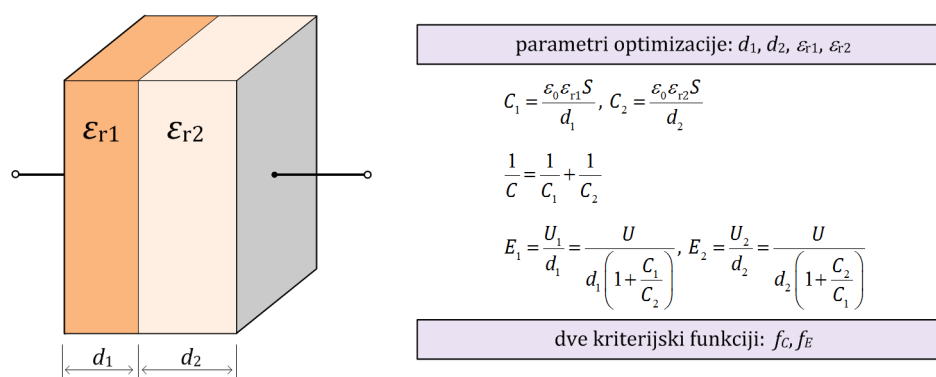


Slika 3.10: Klestenje populacije v algoritmu DEMO

Na sliki 3.10 a so prikazani starši ( $x_i, i=1, \dots, 7$ ) in potomci ( $u_i, i=1, \dots, 7$ ). Na sliki 3.10 b so prikazani osebki, ki po enem koraku algoritma sestavljajo razširjeno populacijo. Po klestenju populacije z uporabo nedominiranega sortiranja in metrike nakopičenosti ostanejo samo še osebki, označeni z belo barvo [35].

### 3.2.2 Predstavitev delovanja algoritma DEMO na preprostem zgledu

V nadaljevanju je predstavljen preprost primer optimizacije ploščatega kondenzatorja, kateremu spreminjamo snovno-geometrijske lastnosti, in sicer razdaljo med ploščama ter vrsto dielektrikov v njegovi notranjosti. Pri tem želimo poiskati takšno konfiguracijo in materiale, s katerim bomo dosegli cilj, in sicer maksimalno kapacitivnost kondenzatorja ob minimalni vrednosti električne poljske jakosti.




Slika 3.11: Kondenzator kot večkriterijski optimizacijski problem

Če pogledamo enačbe na sliki 3.11, vidimo, da se ob zniževanju razdalje  $d$  večja kapacitivnost  $C$ , kar pomeni, da izboljšujemo problem po kriteriju kapacitivnosti, vendar se nam hkrati večja tudi vrednosti električne poljske jakosti  $E$  in s tem poslabšujemo ta kriterij. Nasprotno razmere so v primeru, ko večamo razdaljo, poslabšujemo kriterij kapacitivnosti in izboljšujemo kriterij električne poljske jakosti. Očitno je, da sta ta dva

kriterija konfliktna med seboj in že sedaj vemo, da enoumne rešitve, ki bi zadovoljila oba kriterija hkrati, ni moč najti, temveč moramo poiskati množico enakovrednih rešitev, torej Pareto optimalnih rešitev, ki ležijo na Pareto optimalni fronti.


Algoritem DEMO v postopku reševanja problema najprej inicializira množico rešitev in v naslednjem koraku, za vsakega starša generira potomca. Potomci, ki dominirajo starše, le-te tudi zamenjajo, nedominirani potomci pa so dodatno dodani v populacijo, kar osnovno populacijo razširi.



Slika 3.12: a) Razširjena populacija staršev in potomcev b) Nedominirano sortiranje oz. Pareto rangiranje

Na sliki 3.12 a je prikazan primer razporeditve rešitev v razširjeni populaciji, naslednji korak algoritma pa je krčenje populacije na osnovno velikost populacije, zato se izvede nedominirano sortiranje, kjer algoritem rangira rešitve na več front (slika 3.12 b).

V populaciji skrčeni na osnovno velikost ostanejo rešitve, ki so bližje prvi fronti. Ta postopek algoritem ponavlja, dokler ne pridemo zadovoljivo blizu Pareto optimalni fronti, kot je to prikazano na sliki 3.13.



Slika 3.13: Prikaz Pareto optimalne fronte

Rdeče točke na sliki 3.13 aproksimirajo Pareto optimalno fronto. Praktični pomen iskanja Pareto optimalne rešitve, ki leži na Pareto optimalni fronti, je iskanje boljše rešitve, ki bolje zadovolji vsaj en kriterij, ne da bi se rešitev po ostalih kriterijih pri tem

poslabšala. Na sliki 3.13 imamo primer, ki kaže, da pri določeni vrednosti enega kriterija ( $f_{c1} \sim 0.3$ ) obstajajo rešitve, ki bolje ali slabše zadovoljijo drugi kriterij ( $f_{E1}$  in  $f_{E1'}$ ). Rešitev, s katero v tem primeru najbolje zadovoljimo kriterij  $f_E$ , imenujemo Pareto optimalna rešitev. Če teži kriterija  $f_C$  spremenimo, lahko s Pareto fronte izberemo drugo rešitev, ki nam pri izvedeni izbiri ponovno ponuja najboljšo možno zadovoljitev kriterija  $f_E$ . Tako je Pareto optimalna množica, množica alternativnih in enakovrednih rešitev.

### 3.3 Interpolacijska Kriging metoda

#### 3.3.1 Uvod

Na različnih znanstvenih področjih si pri opisovanju realnih sistemov pomagamo z uporabo modelov, s katerimi izvajamo simulacije. Njihov osnovni namen je bolj podrobno spoznavanje, kako se sistem obnaša pod različnimi pogoji ter kako nanj vplivajo različni vhodni parametri. Simulacijski model je lahko pri tem fizični model ali npr. matematični oz. numerični model (računalniška koda) [66].

Mnogokrat je cilj simulacije parametrična analiza, s katero dobimo odgovor na vprašanje, kako vplivajo vhodni parametri na izhod modela, ali pa tudi, pri katerih vhodnih parametrih sistem deluje optimalno. Za doseganje tega cilja je potrebno simulacijo izvesti velikokrat, kar v osnovi zahteva že optimizacijski algoritem – algoritem DE.

Načrtovanje izdelkov na področju tehnike zahteva določeno mero eksperimentiranja in simulacij, posamična simulacija ali eksperiment pa lahko za svojo izvedbo vzame nekaj minut ali pa celo po več ur skupaj. Posledično iterativni optimizacijski postopki, ki za vsako novo množico spremenljivk modela zahtevajo novo simulacijo oz. oceno KF, trajajo sorazmerno dlje. Zaradi omenjenega se pogosto pojavlja težnja po zmanjšanju števila cenitev KF oz. po izboljšanju učinkovitosti optimizacijskega algoritma [61], [62]. Za zmanjšanje skupne računske zahtevnosti se uporabljajo tudi alternativni pristopi, pri katerih je število dejanskih časovno zahtevnih cenitev KF reducirano. Pri tovrstnih pristopih imajo bistven pomen nadomestki MKE oz. simulacijskih modelov, imenovani *nadomestni modeli* (angl. *Surrogate models*). Le-ti posnemajo obnašanje realnih simulacijskih modelov, vendar so pa pri tem računsko mnogo manj zahtevni. Temeljijo na aproksimaciji originalne "vhodno/izhodne" (angl. *Input/Output - I/O*) funkcije, katero implicitno definira dani simulacijski model, medtem pa nimajo vpliva in ne posegajo v KF oz. v simulacijski model [63]. Nadomestni model tako obravnava simulacijski model kot "črno škatlo", saj uporablja samo njegove vhodno-izhodne veličine, pri tem pa je zanj

princip delovanja simulacijskega modela irelevanten. Zaradi tega je nadomestne modele mogoče uporabljati za vse vrste simulacijskih modelov [66], [67].

Nadomestni modeli, ki so pogosto imenovani tudi *metamodeli*, so neprimerljivo "cenejši" za ocenjevanje KF, kot pa je to primer pri dejanskih simulacijskih modeli. Namen uporabe metamodelov je tako znižati število časovno zahtevnih zagonov simulacijskih modelov. Pri tem nam metamodeli aproksimirajo odziv simulacijskega modela za poljubne vhodne spremenljivke, pri katerih pa zagon simulacijskega modela še ni bil opravljen.

Izhodne veličine iz simulacijskih modelov skupaj s pripadajočo množico vhodov obravnavamo kot prave oz. referenčne vrednosti. Dobimo jih s pomočjo več individualnih zagonov simulacijskega modela, predstavljajo pa osnovo za gradnjo metamodela.

### 3.3.2 Kriging

V okviru disertacije smo se za doseganje računsko bolj učinkovite optimizacije odločili za pristop, kjer delno izpuščamo uporabo časovno zahtevnih simulacijskih modelov za cenitev KF. Izpuščene cenitve KF v tem primeru nadomeščamo z uporabo metamodelov, ki nam na računsko mnogo manj zahteven način podajajo aproksimirane vrednosti KF [64]. To nadomeščanje ima za posledico zmanjšanje skupne računske zahtevnosti, kar bistveno pohitri izvedbo procesa optimizacije.

V uporabi je več različnih metamodelov (metoda umetnih nevronskega omrežja, metoda odzivne ploskve, Kriging,...) [68]-[78], vendar se na področju elektrotehnike v zadnjem času najpogosteje uporabljajo Kriging modeli.

Zgodovina Kriginga sega v leto 1951, ko je južnoafriški inženir rudarstva *Danileu Gerhardus Krige* razvil interpolacijsko metodo za določanje porazdelitve vsebnosti rude v kamnini na osnovi količine v odvzetih vzorcih. Statistično teorijo prostorske interpolacije je postavil francoski matematik *Georges Matheron*, in sicer leta 1963 [65].

Kriging je interpolacijska metoda, ki lahko napove vrednosti izhoda oz. odziv simulacijskega modela za poljubne vhodne spremenljivke. Dejansko pa so napovedi utežena linearna kombinacija izhodnih vrednosti simulacijskega modela. Predpostavka Kriginga je, da npr. bližje kot sta vhodna podatka, bolj pozitivno soodvisni sta napaki napovedi. Verjetnosti izhodov določenih z modelom so konstantne in niso odvisne od lokacije (vhodnih parametrov), kovariance izhodov pa temeljijo le na »razlikah« med pripadajočimi vhodi. Dejansko te kovariance padajo z razdaljo med točkami opazovanja. Kovarianca je mera, koliko se skupaj spreminjata dve spremenljivki. Kriterij napovedi je minimizacija korena razlike kvadratov napake napovedi. Rezultat so vrednosti

metamodela, kjer opazovane točke, ki so bližje točkam napovedi, dobijo večjo utež. Ko z metamodelom napovedujemo odziv za opazovano točko, ki pa je že določen s simulacijskim modelom, potem je napoved metamodela za to točko enaka dejanskemu odzivu simulacijskega modela. Ključno vlogo pri Kriging metodi ima variogram oz. diagram variance razlike med izhodoma določenima za dve vhodni točki. Večja kot je razdalja med tema dvema vhodnima točkama, manjša je njuna odvisnost, vse dokler ta efekt ni zanemarljiv [66].

V primeru Kriginga lahko odziv simulacijskega modela  $y$  v točki  $\mathbf{x}$  zapišemo kot [79]:

$$y(\mathbf{x}) = f(\mathbf{x}) + z(\mathbf{x}) \quad (3.6)$$

kjer je prvi del enačbe znani regresijski model, s katerim globalno aproksimiramo prostor parametrov. Drugi del je naključna funkcija, ki ima srednjo vrednost 0, varianco  $\sigma^2$  ter kovarianco:

$$\text{Cov}[z(\mathbf{x}_i), z(\mathbf{x}_j)] = \sigma^2 \mathbf{R} \quad (3.7)$$

kjer je splošna oblika korelacijske matrike  $\mathbf{R}$  z  $n$  točkami v prostoru parametrov naslednja:

$$\mathbf{R} = R(\mathbf{x}_i, \mathbf{x}_j) = \prod_{k=1}^d \exp\left[-\theta^{(k)} |\mathbf{x}_i^{(k)} - \mathbf{x}_j^{(k)}|^p\right], \quad i, j = 1 \dots n \quad (3.8)$$

$R(\mathbf{x}_i, \mathbf{x}_j)$  je izbrana korelacijska funkcija med opazovanima točkama  $\mathbf{x}_i$  in  $\mathbf{x}_j$  v prostoru parametrov,  $d$  pa je njena dimenzija. V tem delu je uporabljena Gaussova korelacijska funkcija. Za dane korelacijske parametre  $\theta^{(k)}$  ter  $p$  in po vzoru [80], dobimo oceno oz. predikcijo Kriging modela, in sicer v poljubni točki  $\mathbf{x}$ , kot

$$\hat{y}(\mathbf{x}) = \beta^* + \mathbf{r}^T(\mathbf{x}) \mathbf{R}^{-1} (\mathbf{y} - \mathbf{u} \beta^*) \quad (3.9)$$

kjer je  $\mathbf{r}$  vektor korelacijske funkcije  $R(\mathbf{x}, \mathbf{x}_i)$  in velikosti  $n \times 1$ . Pri tem velja  $i = 1, \dots, n$ ,  $\mathbf{y}$  pa je vektor, ki vsebuje odzive dejanskega modela v  $n$  točkah.  $\mathbf{u}$  je tukaj enotski vektor dimenzije  $n \times 1$ , vrednost  $\beta^*$  pa je ocenjena na osnovi metode posplošenih najmanjših kvadratov:

$$\beta^* = (\mathbf{u}^T \mathbf{R}^{-1} \mathbf{u})^{-1} \mathbf{u}^T \mathbf{R}^{-1} \mathbf{y} \quad (3.10)$$

Namesto izbire lahko vrednosti  $\theta^{(k)}$  določimo z oceno po metodi največjega verjetja (angl. *Maximum Likelihood Estimate*) oz. z maksimizacijo naslednje funkcije:

$$\frac{(n \ln(\hat{\sigma}^2) + \ln |\mathbf{R}|)}{2} \quad (3.11)$$


kjer sta  $\hat{\sigma}^2$  (ocena  $\sigma^2$ ) ter  $\mathbf{R}$  funkciji  $\theta^{(k)}$ :

$$\hat{\sigma}^2 = \frac{(\mathbf{y} - \mathbf{u}\beta^*)^T \mathbf{R}^{-1} (\mathbf{y} - \mathbf{u}\beta^*)}{n} \quad (3.12)$$

Ko so vrednosti  $\theta$  enkrat določene, lahko rešimo (3.9). Več podrobnosti o Kriging metodi podaja vir [80].

### 3.3.3 Predstavitev delovanja Kriging metode

V nadaljevanju je predstavljeno delovanje Kriging metode na primeru rekonstrukcije analitično zapisane *Ackley* funkcije. Le-ta spada v nabor standardnih tesnih funkcij, ki se uporabljajo za testiranje optimizacijskih algoritmov. Na sliki 3.14 a je prikazana oblika omenjene funkcije z gostoto izrisa  $400 \times 400$  točk, na sliki 3.14 b pa je prikazana redkejša mreža točk ( $9 \times 9$ ), kjer je vsako vozlišče v mreži definirano z enim parom parametrov funkcije.



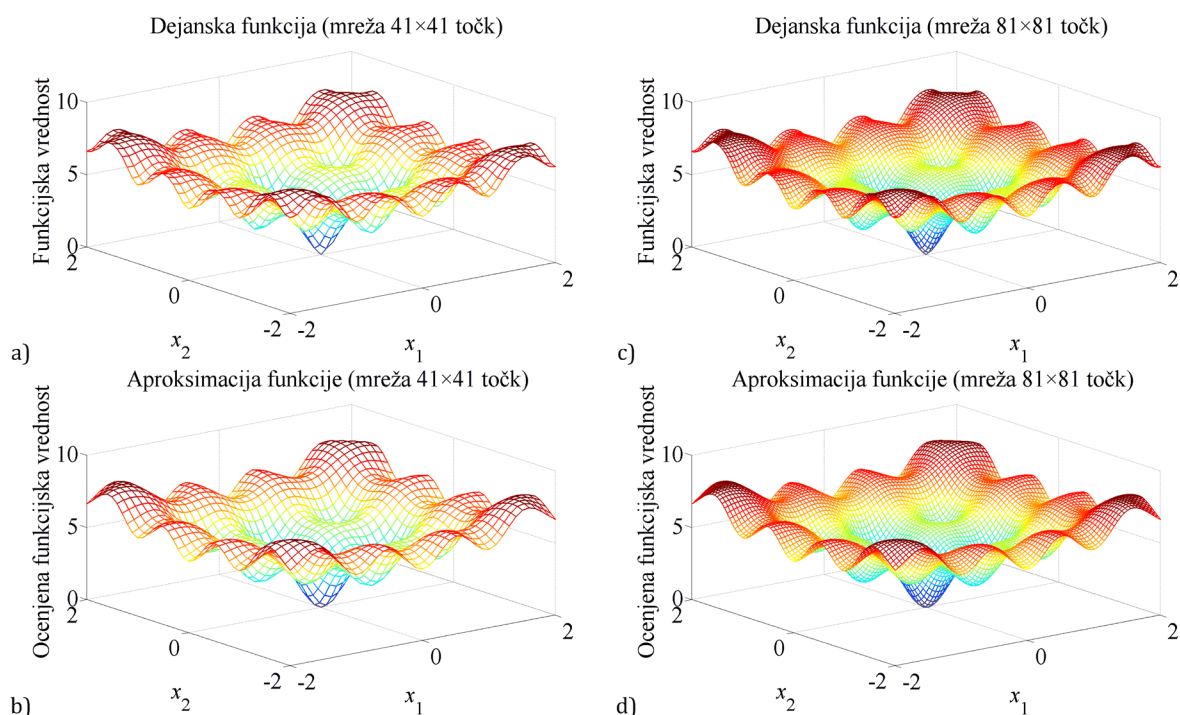
Slika 3.14: a) Graf dejanske 2D *Ackley* funkcije b) Izris odziva metamodela (točke)

Redka mreža na sliki 3.14 b predstavlja referenčne točke s pripadajočimi funkcijskimi vrednostmi, katere so bile izračunane s pomočjo dejanske *Ackley* funkcije. Te referenčne točke smo uporabili kot vhodne podatke za izdelavo metamodela. Tukaj velja popolnoma enaka analogija kot pri simulacijskem modelu, kjer so vhodni parametri modela ekvivalentni koordinatam točk, funkcijske vrednosti pa so ekvivalentne odzivom na izhodu simulacijskega modela. Takšni referenčni I/O podatki so osnova za gradnjo vsakega Kriging modela oz. metamodela. Ko je metamodel izdelan na osnovi postopka, prikazanega v prejšnjem podpoglavju, lahko preverimo, kakšni bi naj bili odzivi modela pri še nepreizkušanih točkah. Drugače zapisano, tukaj dobimo odgovor na vprašanje, kako bi se odzival simulacijski model na poljubne vhodne parametre.

Kot vidimo na sliki 3.14 b, lahko s pomočjo metamodela napovemo funkcijsko vrednost v poljubni točki. Metamodel smo zgradili na podlagi 81 referenčnih točk (mreža  $9 \times 9$ ) in

nato z njegovo pomočjo aproksimirali funkcijske vrednosti za mrežo  $41 \times 41$  točk (črne točke na sliki 3.14 b). V konkretnem primeru je število točk, v katerih smo določili aproksimirano funkcijsko vrednost, praktično več kot 20-krat večje od števila točk, s katerim smo metamodel tudi zgradili. Seveda je lahko to razmerje poljubno, saj lahko aproksimacijo izvedemo za poljubno število točk.

Za boljšo primerjavo sta prikazana še dva primera dejanske in aproksimirane funkcije z različnimi gostotami izrisa (slika 3.15). Vidimo, da je aproksimacija z metamodelom zelo dobra kljub temu, da je zgrajen na osnovi mreže vsega  $9 \times 9$  točk, prikazane na sliki 3.14 b. Če pa pozorno primerjamo izrisa dejanske funkcije na zgornji polovici slike 3.15 z aproksimiranimi izrisoma v spodnji polovici, ugotovimo, da lege in vrednosti nekaterih lokalnih ekstremov malo odstopajo. Pri tem je potrebno izpostaviti, da takšna odstopanja po lokaciji in po iznosu funkcijske vrednosti ne predstavljajo posebnega problema, saj vendarle imamo opravka z aproksimacijo funkcije, ki pa je v konkretnem primeru rekonstruirana na zelo malem vzorcu referenčnih točk. Prav tako je potrebno izpostaviti, da je točnost Kriging modela, s katerim je funkcija aproksimirana, lahko predmet korekcije z dodatnimi referenčnimi točkami, kar pa je posebej relevantno v primeru optimizacije.



Slika 3.15: Primerjava originalne in aproksimirane funkcije pri različnih gostotah izrisa

V naslednjem podpoglavju je predstavljena povezava Kriging modelov z algoritmom DE, ki skozi evolucijo nadomešča trenutne kandidate za rešitev (starše) z novimi (potomci). Kandidati za rešitve so točke v prostoru parametrov, kot smo jih do sedaj imenovali. Nadomeščanje kandidatov se izvaja, kot je opisano v poglavju 2, in sicer le v primeru, če

je potomec bolj kvaliteten od starša, ki je trenutno v populaciji in s katerim se potomec primerja. Izraz "bolj kvaliteten" lahko ima več pomenov, v kontekstu minimizacije problema pa pomeni, da ima potomec oz. nova potencialna rešitev nižjo funkcijsko vrednost.

Za primera s slike 3.15 velja, da aproksimacija metamodela poda globalni optimum, pri katerem je funkcijska vrednost nižja kot pri dejanski funkciji, prav tako je pozicija tega optimuma malo premaknjena. Omenjene razlike so majhne in na grafih težko opazne. Kljub majhnim odstopanjem pa bi se zgodilo, če bi optimirali funkcijo s pomočjo njenega metamodela, da "nepravi" kandidat za rešitev obtiči v populaciji DE, četudi bi se skozi evolucijo metamodel v okolici optimuma korigiral na vrednosti, ki ustrezajo dejanski funkciji. Posledično, bi bila rešitev optimizacijskega algoritma osebek, ki bi predstavljal napačen optimum, optimum, ki v resnici ne obstaja, pravi optimum oz. osebek s parametri dejanskega optimuma, pa ne bi mogel "konkurirati" nepravemu osebku, saj bi bila njegova funkcijska vrednost navidezno nižja.

Rešitev omenjenega problema bi bilo preverjanje potencialno dobrih potomcev z oceno na dejanski funkciji. Tako dobljena funkcijska vrednost bi se v tem primeru smatrala kot eksaktna oz. točna vrednost, katera bi se dotičnemu potomcu pripisala. Seveda bi to pomenil izbris informacije o aproksimirani vrednosti in šele takrat bi lahko dali obravnavanega potomca v mehanizem selekcije, kjer bi ga primerjali s staršem. Ta strategija se bo upoštevala pri izdelavi algoritma DE s Kriging podporo (angl. *Kriging-assisted Differential Evolution* – KADE), kar bo omogočilo novemu optimizacijskemu algoritmu določanje pozicije in vrednosti pravega globalnega optimuma.

### 3.4 Algoritem diferenčne evolucije s Kriging podporo - KADE

Bistvo Kriging podpore algoritmu DE je izboljšava njegove učinkovitosti. Kriging modele tukaj uporabljamo kot nadomestke dejanskih simulacijskih modelov, saj je cenitev KF s pomočjo nadomestnega modela neprimerno hitrejša. Rezultat uporabe Kriging modelov je bistveno krajši čas, ki je potreben za dokončanje optimizacijskega procesa, skrajšanje pa je praktično proporcionalno redukciji števila klicev dejanske KF.

Delovanje algoritma KADE je grafično predstavljeno na sliki 3.16 na strani 57. Na začetku deluje algoritem po korakih izvirnega algoritma DE, ki najprej generira naključno populacijo staršev in vrednosti KF oceni s pomočjo uporabe dejanskega modela. Vsak dejansko ocenjen osebek shranimo v arhiv, le-ta pa v vsaki generaciji služi kot vir podatkov za gradnjo Kriging modela oz. metamodela. V naslednjem koraku DE z mehanizmoma mutacije in križanja generira začasno populacijo potomcev. Ker metamodeli aproksimirajo dejansko KF v prostoru rešitev, potomcem s pomočjo



metamodela napovemo vrednost KF oz. izračunamo njeno aproksimirano vrednost. To informacijo uporabljamo za določanje, ali so novo generirani potomci potencialno boljši od svojih predhodnikov. Če je torej aproksimirana vrednost KF potomca nižja ali enaka dejanski vrednosti KF starša, potem tega potomca označimo kot potencialno dobrega kandidata in ga naknadno ocenimo tudi s klicem dejanske KF. Vse ostale potomce, ki pa ne pokažejo potenciala, zavržemo, ne da bi jim določili dejansko vrednost KF. Z izogibanjem cenitev dejanske KF neobetavnim potomcev prihranimo čas na način, da zmanjšamo število zagonov časovno zahtevnega simulacijskega modela.

Vsak obetaven osebek oz. točko v prostoru parametrov, ki je bila ocenjena z dejansko KF, shranjujemo v prej omenjeni arhiv. Ta arhiv raste z večanjem števila iteracij, gradnja metamodela z vsemi razpoložljivi točkami pa ni praktična, saj čas gradnje modela z večanjem števila točk močno raste. Posledično je potrebno v naprej določiti največje dovoljeno število točk za gradnjo metamodela (angl. *Number of Points for Metamodel Construction* - NPMC), splošni cilj pa je gradnja natančnih metamodelov, vsaj v okolici optimuma. Iz tega sledi, da ožji kot bodo intervali preiskovanja v prostoru parametrov, večja bo gostota točk in s tem natančnost aproksimacije KF. Doseganje visoke natančnosti, vsaj proti koncu evolucije, nam omogoča sam algoritem DE, saj je konvergenca celotne populacije k eni sami rešitvi njegova znana lastnost. To seveda pomeni samodejno ožjenje prostora preiskovanja in s tem avtomatično gostitev točk okoli optimuma KF.

Interes po gradnji metamodela le za določen del prostora parametrov, in sicer za del, v katerem algoritem DE področje aktivno preiskuje, lahko uporabimo pri strategiji filtriranja točk iz arhiva. Prvo pravilo oz. korak pri filtriranju arhiva je, da pri selekciji točk izvzamemo vse tiste, ki ne ležijo v aktivnem oz. preiskovanem delu prostora parametrov. Ker se lahko v evoluciji zgodi, da mehanizem mutacije generira tudi kakšnega potomca, kateremu določeni parameter leži izven intervalov trenutno aktivne populacije, moramo te intervale navidezno razširiti. V našem primeru so intervali posameznih parametrov raztegnjeni za eno svojo dolžino, in sicer za  $1/2$  dolžine na vsaki strani intervala. Osnovni interval definira spodnja in zgornja vrednost posameznega parametra v trenutni populaciji.

Drugi korak pri filtriranju arhiva temelji na oceni nakopičenosti točk v prostoru parametrov. Tukaj izračunamo distančno matriko oz. razdaljo med vsemi možnimi pari točk.

Tretji korak pri strategiji filtriranja je izračun minimalne dovoljene razdalje med točkami na osnovi podatka o trenutnem številu že filtriranih točk in v naprej definirane števila točk, ki ga bomo uporabili pri gradnji metamodela – NPMC.

V četrtem koraku pri vsakemu izmed parov točk, pri katerih je medsebojna razdalja manjša od izračunane minimalne dovoljene, eno točko izbrišemo, in sicer tisto, ki ima višjo vrednost KF.


Ko smo iz arhiva izluščili zelenih NPMC točk oz. osebkov, je zadnji korak izgradnja metamodela in njegova uporaba z namenom aproksimacije KF ter uporabe le-te za oceno potenciala novo generiranih potomcev.

V nadaljevanju izdelamo rang listi trenutne populacije (staršev) in začasne populacije (potomcev), kjer osebke sortiramo naraščajoče glede na dejansko oz. aproksimirano vrednost KF (slika 3.16). Če je na posamezni listi več osebkov z istimi vrednostmi KF, izvedemo permutacijo le-teh. Iz teh dveh list nato izmenično izberemo določeno število indeksov populacije (npr. 10 % NP) ter jih označimo kot privilegirane indekse populacije (angl. *Privileged Population Indexes* – PPI). Ti pridejo v poštev pred delovanjem mehanizma selekcije. Izračun vrednosti KF s pomočjo dejanskega modela za posameznega potomca izvedemo le v primeru, če je njegova aproksimirana vrednost KF nižja od dejanske vrednosti KF starša v trenutni populaciji ali ne glede na to vrednost, če se le indeks potomca iz začasne populacije nahaja na seznamu indeksov PPI. Ta ukrep preprečuje stagnacijo optimizacijskega postopka.

Zadnji element v optimizacijski zanki je mehanizem selekcije. Le-ta zamenja tiste starše, katerih dejansko ocenjeni potomci so boljši oz. imajo nižjo vrednost KF, ostale pa zavrže.

Selekciji sledi vstop v novo generacijo, kjer celoten postopek ponovimo in zgradimo nov metamodel s pomočjo arhiva, ki v tem koraku vključuje še vse novo ocenjene potomce. Z dodajanjem točk v arhiv tako skozi evolucijo gradimo vedno boljše oz. bolj natančne metamodele.

Algoritem KADE je implementiran v programskem orodju Matlab, gradnja metamodelov pa je bila izvedena z uporabo orodja Matlab Kriging Toolbox [81].



Slika 3.16: Grafična predstavitev algoritma KADE

### 3.4.1 Primerjava algoritmov DE in KADE na analitično zapisanih testnih funkcijah

Z namenom primerjave učinkovitosti predstavljenega algoritma KADE z učinkovitostjo klasičnega DE algoritma smo uporabili pet različnih testnih funkcij različnih dimenzij  $D$ . Uporabljene so bile testne funkcije iz tabele 3.1, in sicer *Ackley*, *Michalewicz*, *Rastrigin*, *Rosenbrock* in *Schwefel* [82] – [84].

Tabela 3.1: Seznam testnih funkcij

Testna funkcija	Formula	Domena
Ackley	$f(\mathbf{x}) = 20 + e^{-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}} - e^{\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)}$	$-15 \leq x_i \leq 30$
Michalewicz	$f(\mathbf{x}) = -\sum_{i=1}^n \sin(x_i) \left( \sin\left(\frac{i-x_i}{\pi}\right) \right)^{2m}$	$0 \leq x_i \leq \pi$
Rastrigin	$f(\mathbf{x}) = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i))$	$-5,12 \leq x_i \leq 5,12$
Rosenbrock	$f(\mathbf{x}) = 10n + \sum_{i=1}^{n-1} (x_i - 1)^2 + 100(x_i^2 - x_{i+1})^2$	$-5 \leq x_i \leq 10$
Schwefel	$f(\mathbf{x}) = 418,9829n - \sum_{i=1}^n \left( x_i \sin\left(\sqrt{ x_i }\right) \right)$	$-500 \leq x_i \leq 500$

Funkcijo *Ackley* sestavljajo eksponentni členi, ki pokrivajo njeno površino z množico lokalnih optimumov, sama kompleksnost funkcije pa je zmerna. Njeni lokalni optimumi so enakomerno razporejeni okoli globalnega optimuma, ki je lociran v izhodišču koordinatnega sistema in ima funkcijsko vrednostjo 0.

Funkcija *Michalewicz* je parametrizirana, večmodalna funkcija z množico lokalnih optimumov ( $D!$ ). Večji kot je faktor  $m$  v enačbi (glej Tabela 3.1), težje je locirati optimum. Za namen preskušanja algoritmov smo izbrali vrednost  $m=10$ .

Funkcija *Rastrigin* ima lokalne optimume enakomerno porazdeljene. Globalni optimum s funkcijsko vrednostjo 0 se nahaja v izhodišču koordinatnega sistema.


Funkcija *Rosenbrock* je klasični optimizacijski problem. Njen globalni optimum se nahaja znotraj dolge, ozke in parbolično oblikovane doline. Lociranje doline je trivialen problem, vendar pa je konvergenca težavna, zato je ta problem dober za oceno učinkovitosti optimizacijskih algoritmov. Globalni minimum se nahaja v točki  $\mathbf{x}_i = 1$ , pri tem pa je funkcijska vrednost 0.

Funkcija *Schwefel* ima površino sestavljeno iz mnogih vrhov in dolin. Izredna težavnost te testne funkcije izvira iz dejstva, da je njen drugi najboljši optimum (v tem primeru je to drugi najboljši minimum) pozicijsko zelo oddaljen od globalnega optimuma. Posledično se optimizacijski algoritmi zelo pogosto ujamejo v ta lokalni optimum. Še več,

globalni optimum se nahaja na samem robu prostora parametrov oz. področja preiskovanja tako, da so algoritmi naklonjeni konvergenci v napačni smeri. Globalni optimum KF je za 2D primer -1,8013; za 5D primer -4,68766 ter 10D primer -9,66015.

Primerjavo novega algoritma KADE ter klasičnega algoritma DE smo izvedli na predstavljenih standardnih testnih funkcijah in za primere različnih dimenzij, in sicer 2, 5 in 10D. Rezultati so predstavljeni v tabeli 3.2, pridobljeni pa so na podlagi 25 neodvisnih zagonov algoritma z naslednjimi nastavitvami:  $F = 0,5$ ;  $Cr = 0,5$  in  $NP = 10D$ . Strategija DE je bila izbrana na osnovi uspešnosti rezultatov izvirnega algoritma DE za posamezno testno funkcijo. Z izbranimi strategijami se je klasični DE v glavnem izkazal najbolje pri danih krmilnih parametrih  $F$  in  $Cr$ . Ne glede na izbrano strategijo pa algoritem KADE kaže v splošnem enake trende pri redukciji števila dejanskih cenitev KF. Izbira krmilnih parametrov  $F$  in  $Cr$  je bila namerna, saj se je po nekaj testih algoritmov pri različnih nastavitvah izkazalo, da algoritem KADE pri izbranih nastavitvah omogoča še visoko stopnjo zanesljivosti pri odkrivanju globalnega optimuma.

Na sliki 3.17 so prikazane tri 2D testne funkcije od petih, ki so predstavljene v tabeli 3.1. Preostali dve prikazuje slika 2.15 na strani 33.



Slika 3.17: Testne funkcije a) *Ackley* b) *Michalewicz* in c) *Schwefel*

V tabeli 3.2, kjer so prikazani rezultati optimizacije posameznih testnih funkcij, predstavlja  $D$  dimenzijo problema, VTR pa je zaustavitveni kriterij oz. vrednost funkcije, katero želimo doseči. Kratica *st.* pomeni izbrano strategijo algoritma DE oz. KADE, pri tem pa strategija 1 predstavlja DE/best/1/exp, strategija 2 DE/rand/1/exp in strategija 4 DE/best/2/exp. NMPC predstavlja število točk, ki ga uporabljamo za gradnjo metamodela pri algoritmu KADE. Oznaka  $n_{\text{feval}}$  pomeni povprečno število dejanskih cenitev KF, izračunanih na osnovi 25 neodvisnih zagonov algoritma. NS je število uspešnih zagonov algoritma (angl. *Number of Success*) oz. število, ki pove, kolikokrat je algoritem našel globalni optimum. R predstavlja redukcijo oz. relativno zmanjšanje števila dejanskih cenitev KF (angl. *Reduction*) algoritma KADE v primerjavi z algoritmom DE.

Tabela 3.2: Rezultati optimizacije testnih funkcij z algoritmoma DE in KADE

Funkcija	$D$	VTR	st.	NPCM	$n_{\text{feval}}$ (DE)	$n_{\text{feval}}$ (KADE)	NS DE/KADE	R (%)
Ackley	2			50	1695,68	892,44	25/25	47,4
	5	1e-6	4	100	7201,60	4389,84	25/25	39,0
	10			150	25200,04	16335,04	25/25	35,2
Michalewicz	2	-1,80130		100	783,76	388,16	25/25	50,5
	5	-4,68766	2	100	6670,12	3696,80	25/24	44,6
	10	-9,66015		150	49283,16	25926,81	25/16	47,4
Rastrigin	2			30	1510,36	787,44	25/25	49,9
	5	1e-6	2	100	9755,60	4636,20	25/25	52,5
	10			150	80590,96	26246,70	25/20	67,4
Rosenbrock	2			100	1401,36	488,16	25/25	65,2
	5	1e-6	1	200	19336,95	5176,14	19/22	73,2
	10			100	38923,45	35096,70	22/20	9,8
Schwefel	2			150	1185,95	486,55	22/22	59,0
	5	1e-3	2	50	6988,36	3971,83	25/24	43,2
	10			100	42452,08	29321,43	25/23	30,9

Glede na rezultate lahko zaključimo, da algoritem KADE omogoča občutno znižanje števila cenitev dejanske KF (R), pri tem pa ohranja relativno visoko stopnjo uspešnosti algoritma pri iskanju globalnega optimuma (NS). Rezultati se od primera do primera razlikujejo, povprečno pa je R okoli 50 %. To v praksi pomeni, da algoritem KADE omogoča določitev globalnega optimuma v polovičnem času glede na klasični algoritem DE. Takšna redukcija števila cenitev KF je bila v dosedanjih testih dosežena pri naslednjih parametrih algoritma, in sicer pri konstanti križanja  $Cr = 0,5$ , uteži  $F = 0,5$  ter velikosti populacije  $10D$ , kjer je  $D$  dimenzija problema.

V primeru  $10D$  Michalewicz in Rosenbrock testne funkcije rezultati kažejo odstopanje od splošnega trenda KADE v smislu poslabšanja NS oz. R. Ta problem se da omiliti z velikim povečanjem števila NMPC, vendar je slabost tega početja povečanje časa, ki je potreben za izdelavo samega metamodela.

### 3.4.2 Vpliv krmilnih parametrov na učinkovitost algoritma KADE

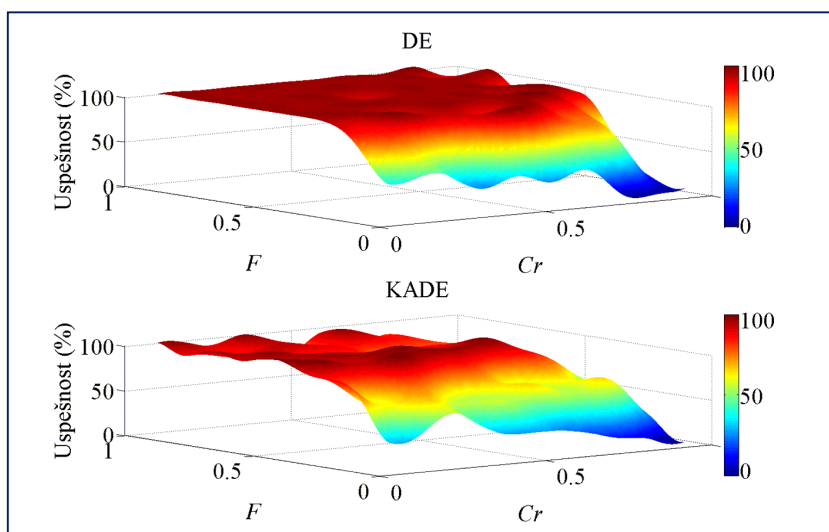
V tem podpoglavju je ocenjen vpliv krmilnih parametrov  $F$  in  $Cr$  na uspešnost ter stopnjo znižanja števila cenitev KF algoritma KADE glede na algoritem DE. Kot testna funkcija je uporabljena  $2D$  Rastrigin funkcija (slika 2.15 a).

Rezultati o uspešnosti algoritmov in številu cenitev dejanske KF, ki so potrebne za lociranje globalnega optimuma, so pridobljeni na osnovi 20 neodvisnih zagonov

posameznega algoritma za posamezno nastavitve krmilnih parametrov. Algoritmu smo stoodstotno uspešnost pripisali, kadar je le-ta pri posamezni nastavitvi vsakič v 20-ih zagonih našel globalni optimum, pri izračunu povprečnega števila cenitev KF pa smo upoštevali samo uspešne zagone [85].

Na sliki 3.18 so predstavljeni rezultati uspešnosti algoritmov DE in KADE v odvisnosti od izbrane uteži  $F$  in konstante križanja  $Cr$ . Vidimo, da je uspešnost algoritma DE stoodstotna na velikem področju, in sicer skoraj pri vseh vrednostih  $F \geq 0,3$  ter  $Cr \leq 0,9$ .


Algoritem KADE sicer ne kaže stoodstotne uspešnosti na tako velikem področju, vendarle pa jo zagotavlja na področju okoli vrednosti s sredine intervala obeh parametrov ter tudi širše. Pri tem lahko izpostavimo intervala  $0,4 \leq F \leq 0,6$  ter  $0 \leq Cr \leq 0,8$ .



Slika 3.18: Uspešnost algoritmov DE in KADE v odvisnosti od  $F$  in  $Cr$


Povprečno število cenitev dejanske KF za uspešne zagone algoritma je prikazano na sliki 3.19, visoke vrednosti pri nastavitvah  $F=0$  ter  $0.8 \leq Cr \leq 1$  pa so posledica neposrednega pripisa najslabših doseženih vrednosti zato, ker algoritma na tem področju nista našla optimuma niti pri enem zagonu.

Pri malih vrednostih  $Cr \leq 0,2$  zahtevata oba algoritma neprimerno večje število cenitev KF kot v primeru večjih, npr. pri vrednostih nad 0,5. Ne glede na izbiro parametrov pa pri istih nastavitvah algoritem KADE prihrani vsaj polovico cenitev KF ( $n_{feval}$ ) glede na algoritem DE.



Slika 3.19: Število cenitev dejanske KF v odvisnosti od  $F$  in  $Cr$

Na sliki 3.20 je prikazan prihranek algoritma KADE pri cenitvah dejanske KF, in sicer tako v absolutnem kot tudi v relativnem iznosu oz. v odstotkih. Zaključimo lahko, da prihranek in s tem učinkovitost algoritma KADE raste z višanjem vrednosti  $Cr$ , a hkrati se glede na sliko 3.18 njegova uspešnost zmanjšuje.



Slika 3.20: Prihranek cenitev dejanske KF pri algoritmu KADE glede na DE

Analiza vpliva parametrov  $F$  in  $Cr$  na učinkovitost algoritmov DE in KADE na konkretnem primeru kaže, da je prihranek števila cenitev dejanske KF pri KADE med 50 in 80 %. Poudariti pa je potrebno, da je stoodstotna uspešnost algoritma KADE zagotovljena le v določeni okolici sredine intervalov  $F$  in  $Cr$ , kjer so prihranki pri cenitvah dejanske KF pri algoritmu KADE v splošnem okoli 50 %, v konkretnem primeru pa tudi okoli 60 % glede na algoritem DE.



## 4. TEORETIČNE OSNOVE ZA NUMERIČNE IZRAČUNE

V tem poglavju so predstavljene teoretične osnove, ki so bile uporabljene pri izračunih za posamezne vrste naprav oz. elementov. Glede na elemente EEO, ki jih to delo obravnava in bodo predstavljeni v naslednjem poglavju, jih lahko razvrstimo v tri sklope. V prvi sklop sodijo izolacijski elementi, ki jih lahko matematično predstavimo z osnovami iz teorije elektrostatičnih polj. V drugi sklop sodi energetski transformator, ki ga lahko obravnavamo s pomočjo izračunov elektromagnetnega in temperaturnega polja. Prvi in drugi sklop tako pokriva teorija polj. V tretji sklop pa sodijo zaščitne naprave oz. v našem primeru plinski odvodnik, katerega delovanje lahko simuliramo z uporabo modelov "črne škatle" oz. z reševanjem eksperimentalno določenih diferencialnih enačb.

### 4.1 Teoretične osnove za obravnavo nekaterih elementov stikalnih naprav

Teorija polj temelji na sistemu PDE, ki jih poznamo pod imenom *Maxwellove* enačbe. Sistem *Maxwellovih* enačb je sestavljen iz dveh glavnih enačb (4.1) in (4.2), dveh pomožnih, oziroma ene ( $-\operatorname{div}\mathbf{J} = -\partial\rho/\partial t$ ), ki predstavlja ekvivalenten zapis enačbama (4.3) in (4.4) ter enačb (4.5), (4.6) in (4.7), ki skupaj tvorijo popolni zapis:

$$\operatorname{rot}\mathbf{H} = \mathbf{J} + \frac{\partial\mathbf{D}}{\partial t} \quad (4.1)$$

$$\operatorname{rot}\mathbf{E} = -\frac{\partial\mathbf{B}}{\partial t} \quad (4.2)$$

$$\operatorname{div}\mathbf{B} = 0 \quad (4.3)$$

$$\operatorname{div} \mathbf{D} = \rho \quad (4.4)$$

$$\mathbf{D} = \varepsilon_0 \mathbf{E} + \mathbf{P} = \varepsilon \mathbf{E} \quad (4.5)$$

$$\mathbf{B} = \mu_0 (\mathbf{H} + \mathbf{M}) = \mu \mathbf{H} \quad (4.6)$$

$$\mathbf{J} = \sigma \mathbf{E} + \mathbf{J}_i = \sigma \mathbf{E} \quad (4.7)$$

kjer so:

$\mathbf{H}$  vektor magnetne poljske jakosti [A/m]

$\mathbf{J}$  vektor gostote električnega toka [A/m<sup>2</sup>]

$\mathbf{J}_i$  vektor gostote električnega toka zunanjih izvorov [A/m<sup>2</sup>]

$\mathbf{D}$  vektor gostote električnega pretoka [As/m<sup>2</sup>]

$\mathbf{E}$  vektor električne poljske jakosti [V/m]

$\mathbf{B}$  vektor gostote magnetnega pretoka [Vs/m<sup>2</sup>]

$\mathbf{M}$  vektor magnetne polarizacije [A/m]

$\mathbf{P}$  vektor električne polarizacije [As/m<sup>2</sup>]

$\rho$  električna gostota naboja [As/m<sup>3</sup>]

$\mu$  permeabilnost [Vs/Am]

$\varepsilon$  dielektričnost [As/Vm]

$\sigma$  prevodnost [S]

Permeabilnost  $\mu$ , dielektričnost  $\varepsilon$  in prevodnost  $\sigma$  opisujejo lastnosti medija in so v preprostih homogenih, izotropnih in linearno odvisnih primerih ( $\mathbf{B} - \mathbf{H}$  karakteristikah) konstantne skalarne vrednosti neodvisne od polja, v katerem se nahajajo. Na splošno pa se lahko te vrednosti spreminjajo, recimo v prostoru, kjer je medij nehomogen, anizotropen ali ima nelinearno karakteristiko [86].

Gradient, divergenca in rotor so matematični operatorji. Gradient je diferencialna operacija nad poljubno skalarno funkcijo npr.  $\varphi$ , ki nam da vektorsko funkcijo npr.  $\mathbf{A}$ , ki ima smer normale na ploskev  $\varphi = konst.$ , po vrednosti pa je enaka odvodu funkcije  $\varphi$  v smeri normale na  $\varphi = konst.$

$$\operatorname{grad} \varphi = \nabla \varphi = \mathbf{i} \frac{\partial \varphi}{\partial x} + \mathbf{j} \frac{\partial \varphi}{\partial y} + \mathbf{k} \frac{\partial \varphi}{\partial z} \quad (4.8)$$

Vektorsko polje  $\operatorname{grad} \varphi$  ponazarjamo s črtami, ki jih v splošnem imenujemo vektornice. To so krivulje v prostoru, katerih tangenta se v vsaki točki ujema s smerjo vektorja  $\mathbf{A}$ .

Divergenca je diferencialna operacija nad poljubno vektorsko funkcijo npr.  $\mathbf{A}$ , ki da skalarno funkcijo npr.  $\phi$ . Divergenca je definirana v vsaki točki polja  $\mathbf{A}$  s komponentami  $A_x, A_y, A_z$  in je odvod po prostornini tega polja:

$$\phi = \operatorname{div}\mathbf{A} = \nabla\mathbf{A} = \frac{\partial A_x}{\partial x} + \frac{\partial A_y}{\partial y} + \frac{\partial A_z}{\partial z} \quad (4.9)$$

Rotor je diferencialna operacija nad poljubno vektorsko funkcijo, npr.  $\mathbf{A}$ , ki da vektorsko funkcijo npr.  $\mathbf{R}$ . Rotor je definiran v vsaki točki polja  $\mathbf{A}$  in je odvod po prostornini tega polja.

$$\mathbf{R} = \operatorname{rot}\mathbf{A} = \nabla \times \mathbf{A} = \left(\frac{\partial A_z}{\partial y} - \frac{\partial A_y}{\partial z}\right)\mathbf{i} + \left(\frac{\partial A_x}{\partial z} - \frac{\partial A_z}{\partial x}\right)\mathbf{j} + \left(\frac{\partial A_y}{\partial x} - \frac{\partial A_x}{\partial y}\right)\mathbf{k} \quad (4.10)$$

Elektromagnetno polje je lahko v celoti opisano z dvema vektorjema polja ( $\mathbf{E}$  in  $\mathbf{H}$ ), medtem ko so ostale veličine dosegljive preko osnovnih enačb (4.5) do (4.7). Ta način prikazovanja vključuje šest skalarnih funkcij (tri komponente za vsak vektor polja), kar pa se izkaže za nepotrebno. Uvedba tako imenovanih "potencialnih funkcij" omogoča opis elektromagnetnega polja z manjšim številom skalarnih funkcij. Ta predstavitev ima tudi to prednost, da se potencialna funkcija vedno lahko prikaže kot zvezna funkcija, vektorji pa so nezvezna funkcija, kadarkoli se lastnost materiala spremeni (na robovih materiala).

Niz Maxwellovih enačb, ki je bil zapisan, velja za časovno odvisno polje. Tovrstno polje predstavlja tako s teoretičnega kot praktičnega vidika zelo zahtevno nalogo, ki jo brez dodatnih poenostavitev ne moremo rešiti. Deloma se problem poenostavi, ko obravnavamo časovno neodvisno polje (elektrostatično, magnetostatično polje) kot poseben primer časovno odvisnega polja. V tem primeru se Maxwellove enačbe poenostavijo, saj odpadejo vsi členi  $\frac{\partial}{\partial t}$ .

S statično aproksimacijo polja smemo analizirati večino aplikacij in raziskav nizkofrekvenčnih električnih naprav. V primeru, ko zanemarimo časovno spreminjanje poljskih veličin, odpravimo soodvisnost med električnim in magnetnim poljem.

#### 4.1.1 Elektrostatično polje


Pri stacionarnih pogojih lahko iz Maxwellovih enačb (4.2) in (4.4) izpeljemo enačbe za električno poljsko jakost  $\mathbf{E}$ , gostoto električnega pretoka  $\mathbf{D}$ , izraženo s prostorsko gostoto naboja  $\rho = dQ/dV$ , kjer  $Q$  predstavlja elektrino, ter z upoštevanjem enačbe (4.5) v celoti opišemo statično električno polje [86]:

$$\nabla \times \mathbf{E} = 0 \quad (4.11)$$

$$\nabla \mathbf{D} = \rho, \text{ na področju } \Omega \quad (4.12)$$

$$\mathbf{D} = \epsilon \mathbf{E} \quad (4.13)$$

Pri pisanju robnih pogojev predstavlja  $\mathbf{n}$  normalo na obravnavano površino z upoštevanjem področja  $\Omega$ , ki ga prikazuje slika 4.1.



Slika 4.1: Predstavitev elektrostatičnega problema

Na delu površine  $\Gamma_E$  površine  $\Gamma$ , ki meji na področje oz. domeno  $\Omega$ , je tangencialna komponenta električnega polja znana in izražena kot dana površinska magnetna tokovna gostota:

$$\mathbf{E} \times \mathbf{n} = \mathbf{K}_m, \text{ na } \Gamma_E \quad (4.14)$$

V večini primerov je površina  $\Gamma_E$  sestavljena iz prevodnih področij oz. elektrod, kjer ni prisotna površinska magnetna tokovna gostota ( $\mathbf{K}_m = 0$ ). V primeru, ko je  $\Gamma_E$  sestavljena iz  $n_E$  področij, mora biti določen eden izmed naslednjih  $(n_E - 1)$  integralov, in sicer ali integral  $\mathbf{D}$  nad  $(n_E - 1)$  površinskih področij (nabojev) ali integral  $\mathbf{E}$  vzdolž linij, ki povezujejo eno področje  $\Gamma_E$  s preostalimi  $(n_E - 1)$  področji:

$$\int_{\Gamma_{E_i}} \mathbf{D} \cdot \mathbf{n} \, d\Gamma = Q_i, \quad i = 1, 2, \dots, n_E - 1 \text{ ali} \quad (4.15)$$

$$\int_{C_{E_i}} \mathbf{E} \cdot d\mathbf{l} = \varphi_i, \quad i = 1, 2, \dots, n_E - 1 \quad (4.16)$$

kjer  $\Gamma_{E_i}$  označuje  $i$ -to področje  $\Gamma_E$ ,  $C_{E_i}$  pa je krivulja, ki povezuje površino  $\Gamma_{E_i}$  s področjem  $\Gamma_{E_{n_E}}$ . Na delu  $\Gamma_D$ , ki meji na površino  $\Gamma$  ( $\Gamma_D + \Gamma_E = \Gamma$ ), je normalna komponenta gostote električnega pretoka dana kot gostota površinskega naboja  $\rho_s$ :

$$\mathbf{D} \cdot \mathbf{n} = -\rho_s, \text{ na robu } \Gamma_D. \quad (4.17)$$

Površino  $\Gamma_D$  običajno sestavljajo področja, ki imajo vrednost normalne komponente gostote pretoka enako 0 (običajno so to simetrične ploskve, kjer je gostota površinskega

naboja  $\rho_S = 0$ ). Upoštevanje robnih pogojev (4.15) do (4.17) v enačbah (4.11) do (4.13) podaja vedno samo eno rešitev elektrostatičnega polja z vektorjema  $\mathbf{D}$  in  $\mathbf{E}$ . V dokaz edinstvenosti rešitve bomo v nadaljevanju najprej predpostavili, da obstajata dve rešitvi, katerih diferenco lahko označimo z  $\mathbf{D}^{(0)}$  in  $\mathbf{E}^{(0)}$ . Izpolnjeni morajo biti naslednji pogoji [86]:

$$\nabla \times \mathbf{E}^{(0)} = 0 \quad (4.18)$$

$$\nabla \mathbf{D}^{(0)} = 0, \text{ v območju } \Omega \quad (4.19)$$

$$\mathbf{D}^{(0)} = \varepsilon \mathbf{E}^{(0)} \quad (4.20)$$

$$\mathbf{E}^{(0)} \times \mathbf{n} = 0, \text{ na robu } \Gamma_E \quad (4.21)$$

$$\int_{\Gamma_{E_i}} \mathbf{D}^{(0)} \mathbf{n} d\Gamma = 0, \quad i = 1, 2, \dots, n_E - 1 \quad (4.22)$$

$$\int_{C_{E_i}} \mathbf{E}^{(0)} d\mathbf{l} = 0, \quad i = 1, 2, \dots, n_E - 1 \quad (4.23)$$

$$\mathbf{D}^{(0)} \mathbf{n} = 0, \text{ na robu } \Gamma_D \quad (4.24)$$

Če dokažemo, da je diferenca polja  $\mathbf{D}^{(0)}$  in  $\mathbf{E}^{(0)}$  enaka 0, je zagotovljena edinstvenost rešitve. Dokaz je osnovan na izračunu energije:

$$W^{(0)} = \int_{\Omega} \mathbf{D}^{(0)} \mathbf{E}^{(0)} d\Omega \quad (4.25)$$

katere vrednost je nič. Ker je v (4.20) dielektrična konstanta  $\varepsilon$  pozitivna, je diferenca polja enaka 0. V (4.18) lahko  $\mathbf{E}^{(0)}$  zapišemo kot:

$$\mathbf{E}^{(0)} = -\nabla \varphi^{(0)} \quad (4.26)$$

Z uporabo vektorske algebre, energijo  $W^{(0)}$  zapišemo kot:

$$-\int_{\Omega} \nabla \varphi^{(0)} \mathbf{D}^{(0)} d\Omega = \int_{\Omega} \nabla \varphi^{(0)} \mathbf{D}^{(0)} d\Omega - \oint_{\Gamma} \varphi^{(0)} \mathbf{D}^{(0)} \mathbf{n} d\Gamma \quad (4.27)$$

Z upoštevanjem enačbe (4.19) je volumski integral na desni strani enak 0, medtem ko enačba (4.24) nakazuje, da površinski integral izginja na  $\Gamma_D$ . Glede na robni pogoj v enačbi (4.21) je potencial  $\varphi_i^{(0)}$  konstanten na  $\Gamma_E$ . Če vzamemo njegovo vrednost na površini  $\Gamma_{E_i}$  kot 0, dobimo:

$$W^{(0)} = -\sum_{i=1}^{n_E-1} \varphi_i^{(0)} \oint_{\Gamma_{E_i}} \mathbf{D}^{(0)} \mathbf{n} d\Gamma \quad (4.28)$$

kjer je  $\varphi_i^{(0)}$  konstantna vrednost  $\varphi^{(0)}$  na robu  $\Gamma_{E_i}$ . Na robu  $C_{E_i}$  je potencial  $\varphi^{(0)}$  določen kot

$$\varphi_i^{(0)} = \int_{C_{E_i}} \mathbf{E}^{(0)} d\mathbf{l} \quad (4.29)$$

kar dokazuje, da je  $W^{(0)} = 0$  glede na pogoje iz enačb (4.22) in (4.23), torej je rešitev enačb (4.11) do (4.13) z robnimi pogoji (4.14) do (4.17) edinstvena.

#### 4.1.2 Električni skalarni potencial

Osnovnega zapisa elektrostatičnega polja, ki ga opisujeta dve PDE prvega reda in ena pomožna enačba ( $\nabla \times \mathbf{E} = 0, \nabla \mathbf{D} = \rho$  in  $\mathbf{D} = \varepsilon \mathbf{E}$ ), običajno ne uporabljamo in raje uvedemo pomožno veličino – električni potencial  $\varphi$ . Te veličine seveda ne moremo kar tako vpeljati, ne da bi upoštevali osnovni zapis, vpeljavo pa nam omogočajo relacije veličin v osnovnem zapisu;  $\nabla \times (\nabla x) \equiv 0$ . Torej upošteva prvo enačbo osnovnega zapisa polja ( $\nabla \times \mathbf{E} = 0$ ) lahko zapišemo:

$$\mathbf{E} = -\nabla \varphi \quad (4.30)$$

Ta formulacija zagotavlja izpolnitev (4.11). Z uporabo (4.12), (4.13) pa se osnovni zapis polja preoblikuje v zapis z eno samo PDE drugega reda:

$$-\nabla(\varepsilon \nabla \varphi) = \rho, \text{ v } \Omega \quad (4.31)$$

torej posplošeno *Laplace-Poissonovo* enačbo.

Robni pogoj (4.14) dovoljuje specifikacijo potenciala  $\varphi$  na  $\Gamma_E$ , če se dodatni pogoji iz (4.15) nanašajo na napetosti površinskih področij oz. sekcij. Na vsaki nestični sekciji  $\Gamma_{Ei}$  površine  $\Gamma_E$  lahko skalarni potencial  $\varphi_{0i}$  določimo tako, da izberemo poljubno točko  $P_i$  na vsaki površinski sekciji  $\Gamma_{Ei}$  in določimo:

$$\varphi_{0i} = 0, \text{ pri } P_i \quad (4.32)$$

V vsaki drugi točki  $P$  na  $\Gamma_{Ei}$  je  $\varphi_{0i}$  definiran kot:

$$\varphi_{0i} = \int_{C_p} (\mathbf{n} \times \mathbf{K}_m) d\mathbf{l} \quad (4.33)$$

kjer je  $C_p$  opazovana krivulja, ki leži na  $\Gamma_{Ei}$  in povezuje  $P$  s  $P_i$ . Vrednost integrala je neodvisna od poti integriranja oz. izbire krivulje. Na elektrodah in simetričnih ploskvah je v večini praktičnih primerov je  $\varphi_{0i} = 0$ , kjer je  $\mathbf{K}_m = 0$ . Negativni gradienti  $\varphi_{0i}$  očitno zadovoljujejo robni pogoj iz enačbe (4.14), tako da  $\varphi_{0i}$  določa električni skalarni potencial  $\varphi$  na  $\Gamma_{Ei}$  na meji konstantne vrednosti potenciala:

$$\varphi = \varphi_{0i} + \varphi_i, \text{ na } \Gamma_{Ei} \quad (4.34)$$

Na površini sekcije  $\Gamma_{E_{n_E}}$  lahko izberemo za  $\varphi_{n_E}$  vrednost 0. Preostale  $(n_E - 1)$  vrednosti so dane z napetostmi, ki so določene po enačbi  $\int_{C_{E_i}} \mathbf{E} d\mathbf{l} = \varphi_i$ . Tako so linijski integrali vzdolž krivulj  $C_{E_i}$  razlike potencialnih vrednosti v končnih točkah krivulj. Če povzamemo, je robni pogoj v (4.14) za električni skalarni potencial formuliran kot:

$$\varphi = U_0, \text{ na robu } \Gamma_E \quad (4.35)$$

kjer je znana funkcija  $U_0$  enaka vsoti funkcije  $\varphi_{0i}$  in napetosti  $U_i$  na  $i$ -ti sekciji  $\Gamma_E$ . Pogoj v (4.35) je *Dirichletov* robni pogoj.

Robni pogoj v enačbi (4.17) predstavlja *Neumanov* robni pogoj za  $\varphi$ :

$$\mathbf{n}\varepsilon\nabla\varphi = \rho_s, \text{ na robu } \Gamma_D \quad (4.36)$$

Če povzamemo, električni skalarni potencial zadovoljuje parcialno PDE drugega reda (4.31) z robnima pogojsma (4.35) in (4.36).

### 4.1.3 Zapis elektrostatičnega polja z Galerkinovim postopkom

PDE drugega reda (4.31) opisuje elektrostatično polje s skalarnim potencialom  $\varphi$ . Zapišemo jo lahko tudi v naslednji obliki [3], [87]:

$$-\text{div}\varepsilon\text{grad}\varphi = \rho \quad (4.37)$$

kjer je skalarni potencial funkcija, ki jo iščemo na celotnem področju  $\Omega$ ,  $\rho$  pa je znana funkcija, ki predstavlja površinsko gostoto električnega naboja kot posledica izvora  $Q$ .

V nadaljevanju sledi prikaz aproksimativnega reševanja diferencialne enačbe, kjer s pomočjo aproksimacijske funkcije zapišemo iskano rešitev skalarnega potenciala  $\varphi$  na celotnem območju  $\Omega$ :

$$\varphi \approx \varphi^{(n)} = \varphi_E + \sum_{j=1}^n h_j \varphi_j \quad (4.38)$$

pri tem je  $\varphi_E$  vrednost potenciala na *Dirichletovem* robnem pogoju,  $\varphi_j$  je neznana vrednost potenciala  $\varphi$  v  $j$ -tem vozlišču in  $h_j$  so posebne interpolacijske funkcije, imenovane tudi oblikovne funkcije. Ker poteka določitev parametrov te funkcije direktno v povezavi z diferencialno enačbo, postane s tem funkcija najboljši približek rešitve diferencialne enačbe.

Ena izmed možnosti aproksimativnega reševanja diferencialnih enačb je metoda utežnih ostankov, ki je največkrat izpeljana na osnovi Galerkinove metode. Ko aproksimativna rešitev zadosti robnim pogojem, se pogoj minimuma utežnih ostankov formulira kot:

$$\int_{\Omega} R w d\Omega = 0 \quad (4.39)$$

kjer je  $R$  residuum oziroma ostanek med točno in približno vrednostjo,  $w$  pa izbrana utežna funkcija. Če v osnovni nastavek (4.39) namesto  $R$ , vstavimo diferencialno enačbo (4.37), dobimo t. i. šibko obliko (angl. *Weak form*) zapisa elektrostatičnega polja, ki je osnova *Galerkinovega* postopka:

$$\int_{\Omega} [\operatorname{div} \varepsilon \operatorname{grad} \varphi + \rho] w d\Omega = 0 \quad (4.40)$$

Glede na iskano rešitev skalarne funkcije  $\varphi$  je zapis diferencialne enačbe (4.37) ekvivalenten zapisu s pomočjo šibke oblike (4.40). Če je vrednost v oklepajih enaka nič, potem je tudi (4.40) enaka nič za poljubno izbrano utežno funkcijo  $w$ . Prvi del enačbe predstavlja diferencialni operator drugega reda, ki ga s preureditvijo znižamo v operator prvega reda. Veljata naslednji povezavi:

$$\operatorname{grad}(\varphi w) = \varphi \operatorname{grad} w + w \operatorname{grad} \varphi \quad (4.41)$$

$$\operatorname{div}(\varphi w) = w \operatorname{grad} \varphi + \varphi \operatorname{div} w \quad (4.42)$$

Tako lahko prvi del izraza v enačbi (4.40) zapišemo kot:

$$[\operatorname{div}(\varepsilon \operatorname{grad} \varphi)] w = w \operatorname{grad} \varphi \operatorname{grad} \varepsilon + \varepsilon \varphi \operatorname{div}(\operatorname{grad} \varphi) \quad (4.43)$$

Zadnji člen v (4.43) z upoštevanjem (4.42) zapišemo v obliki:

$$\varepsilon \varphi \operatorname{div}(\operatorname{grad} \varphi) = \operatorname{div}[\varepsilon \varphi \operatorname{grad} \varphi] - \operatorname{grad} \varphi \operatorname{grad} \varepsilon \varphi \quad (4.44)$$

kjer zadnji člen v (4.41) predstavlja zapisano pravilo. Enačba (4.43) dobi obliko:

$$[\operatorname{div}(\varepsilon \operatorname{grad} \varphi)] w = -(\varepsilon \operatorname{grad} \varphi)(\operatorname{grad} w) + \operatorname{div}[w \varepsilon \operatorname{grad} \varphi] \quad (4.45)$$

Prvi del enačbe (4.40), zapisane v šibki obliki, lahko sedaj zapišemo kot:

$$\int_{\Omega} (\operatorname{div} \varepsilon \operatorname{grad} \varphi) w d\Omega = - \int_{\Omega} (\varepsilon \operatorname{grad} \varphi) \operatorname{grad} w d\Omega + \int_{\Omega} \operatorname{div}(w \varepsilon \operatorname{grad} \varphi) d\Omega \quad (4.46)$$

Če v zadnjem členu upoštevamo še Gaussov izrek, potem dobi celotna šibka oblika diferencialne enačbe (4.40) naslednjo obliko:

$$\int_{\Omega} (\varepsilon \operatorname{grad} \varphi) \operatorname{grad} w d\Omega - \oint_{\Gamma} (w \varepsilon \operatorname{grad} \varphi) n d\Gamma = \int_{\Omega} \rho w d\Omega \quad (4.47)$$

Od utežne skalarne funkcije  $w$  zahtevajmo, da bo enaka nič na celotnem *Dirichletovem* robu. Z upoštevanjem Neumanovih robnih pogojev (4.36) preide (4.47) v obliko:



$$\int_{\Omega} (\varepsilon \text{grad} \varphi) \text{grad} w \, d\Omega - \int_{\Gamma_D} w \rho_s \, d\Gamma = \int_{\Omega} \rho w \, d\Omega \quad (4.48)$$

Rešitev nastale enačbe poiščemo aproksimativno, tako da za vrednosti potenciala vstavimo nastavek (4.38). Pri tem izberemo toliko utežnih funkcij  $w_i$ , kolikor imamo neznanke  $\varphi_i$ .

$$\int_{\Omega} \left( \varepsilon \text{grad} \left( \varphi_E + \sum_{j=1}^n h_j \varphi_j \right) \right) \text{grad} w_i \, d\Omega = \int_{\Gamma_D} w \rho_s \, d\Gamma + \int_{\Omega} \rho w \, d\Omega; \quad i = 1, 2, \dots, n \quad (4.49)$$

Po preureditvi dobimo naslednji zapis:

$$\sum_{j=1}^n \varphi_j \int_{\Omega} (\varepsilon \text{grad} h_j) \text{grad} w_i \, d\Omega = \int_{\Omega} (\varepsilon \text{grad} \varphi_E) \text{grad} w_i \, d\Omega + \int_{\Gamma_D} w \rho_s \, d\Gamma + \int_{\Omega} \rho w \, d\Omega; \quad i = 1, 2, \dots, n \quad (4.50)$$

ki dejansko predstavlja sistem  $n$  linearnih enačb z neznanimi koeficienti  $\varphi_j$  vektorja  $\varphi$ :

$$\mathbf{S} \varphi = \mathbf{d} \quad (4.51)$$

Koeficienti  $s_{ij}$  matrice  $\mathbf{S}$  so določeni z zapisom (3.47),  $i$ -ti koeficient vektorja  $\mathbf{d}$  pa z enačbo (3.48).

$$s_{ij} = \int_{\Omega} (\varepsilon \text{grad} h_j) \text{grad} w_i \, d\Omega \quad (4.52)$$

$$d_i = \int_{\Omega} (\varepsilon \text{grad} \varphi_E) \text{grad} w_i \, d\Omega + \int_{\Gamma_D} w \rho_s \, d\Gamma + \int_{\Omega} \rho w \, d\Omega \quad (4.53)$$

Bistvo Galerkinove metode določa, da z izbiro utežne funkcije  $w_i = h_j$  postane sistem simetričen. Najpogosteje uporabljen in najbolj prilagodljiv postopek za rešitev enačb, izpeljanih na osnovi Galerkinove metode, predstavlja MKE.

#### 4.1.4 Metoda končnih elementov


Bistven problem Galerkinove metode je izbira razširitvenih funkcij, ki izpolnjujejo Dirichletove robne pogoje in oblikujejo celoten niz za aproksimacije potencialov. Najbolj prilagodljiv način je uporaba MKE metode.

Osnovni princip metode leži v razdelitvi opazovanega področja ali telesa na končno število manjših in natančno omejenih področij, ki jih imenujemo končni elementi (KE). S tem smo, fizikalno gledano, kontinuum zamenjali z diskretnim modelom, matematično gledano, pa smo problem iz področja analize prevedli v področje algebre. Rešitve, ki jih

dobimo z MKE so približek dejanskim vrednostim, v splošnem pa velja, da se napake diskretizacije zmanjšujejo s povečanjem števila KE. Na natančnost seveda vpliva tudi izbira interpolacijskih funkcij, ki aproksimirajo polje veličin v elementu. Posebni interpolacijski polinomi, imenovani oblikovne funkcije elementa, so uporabljeni za aproksimacijo potencialov v vsakem elementu. Ena oblikovna funkcija elementa  $N_k^{(e)}$  je povezana z vsakim vozliščem, v elementu v katerem ima vrednost 1, v vseh drugih pa 0:

$$N_k^{(e)} \begin{cases} 1 & \text{v vozlišču } k \\ 0 & \text{v vseh ostalih vozliščih} \end{cases} \quad (4.54)$$

Oblikovne funkcije elementov so določene v lokalnem koordinatnem sistemu, povezanim z vsakim elementom [86]. Na primer, dvodimenzionalni osemvozliščni pravokotni element je prikazan v lokalnem in globalnem koordinatnem sistemu na sliki 4.2.




Slika 4.2: Osemvozliščni kvadratni element v lokalnem in globalnem koordinatnem sistemu

Oblikovne funkcije elementov so lahko zapisane kot:

$$\begin{aligned} N_k^{(e)}(\xi, \eta) &= \frac{1}{4}(1 + \xi\xi_k)(1 + \eta\eta_k)(\xi\xi_k + \eta\eta_k - 1) \\ &\text{za vogalna vozlišča } (\xi_k = \pm 1, \eta_k = \pm 1) \\ N_k^{(e)}(\xi, \eta) &= \frac{1}{2}(1 - \xi^2)(1 + \eta\eta_k) \\ &\text{za vmesna vozlišča } (\xi_k = 0, \eta_k = \pm 1) \\ N_k^{(e)}(\xi, \eta) &= \frac{1}{2}(1 - \eta^2)(1 + \xi\xi_k) \\ &\text{za vmesna vozlišča } (\eta_k = 0, \xi_k = \pm 1) \end{aligned} \quad (4.55)$$

kjer sta  $(\xi_k, \eta_k)$  lokalni koordinati vozlišča  $k$ . Oblikovne funkcije predstavljene v (4.55) so prikazane na sliki 4.3. To so kvadratni polinomi in zlahka izpolnjujejo pogoje (4.54). V treh dimenzijah so prisotne tri lokalne spremenljivke  $\xi$ ,  $\eta$  in  $\zeta$ .



Slika 4.3: Oblikovne funkcije elementa z osemvozliščnim kvadratnim elementom

Spremembo med lokalnimi in globalnimi koordinatami elementa z  $n_n^{(e)}$  vozlišči lahko določimo s pomočjo lokalno določenih oblikovnih funkcij:

$$\begin{aligned} x(\xi, \eta, \zeta) &= \sum_{k=1}^{n_n^{(e)}} x_k N_k^{(e)}(\xi, \eta, \zeta) \\ y(\xi, \eta, \zeta) &= \sum_{k=1}^{n_n^{(e)}} y_k N_k^{(e)}(\xi, \eta, \zeta) \\ z(\xi, \eta, \zeta) &= \sum_{k=1}^{n_n^{(e)}} z_k N_k^{(e)}(\xi, \eta, \zeta) \end{aligned} \quad (4.56)$$

kjer so  $x_k, y_k$  in  $z_k$  globalne koordinate  $k$ -tega vozlišča. Lokalne koordinate sečišč se spremenijo v njihove globalne koordinate glede na lastnost (4.54) oblikovnih funkcij elementa. Ta sprememba prav tako določa oblikovne funkcije elementa v smislu globalnih koordinat  $x, y$  in  $z$ .

Funkcijo, ki določa aproksimacijsko vrednost potencialni funkciji, lahko v elementu zapišemo kot:

$$\varphi^{(e)}(x, y, z) = \sum_{k=1}^{n_n^{(e)}} \varphi_k N_k^{(e)}(x, y, z) \quad (4.57)$$

kjer je  $\varphi_k$  vrednost potenciala v vozlišču  $k$  in  $n_n$  število globalnih vozlišč. Pogoji (4.54) zagotavljajo, da funkcija  $\varphi^{(e)}$  zavzame vrednost  $\varphi_k$  pri  $k$ -tem vozlišču.

Globalne oblikovne funkcije lahko služijo kot razširjene funkcije aproksimaciji potencialov v *Galerkinovi* metodi. Možno jih je uporabiti tudi na neposreden način pri oblikovanju funkcij, ki izpolnjujejo *Dirichletove* robne pogoje. Na primer, če mora skalarni potencial  $\varphi$  izpolnjevati Dirichletov robni pogoj

$$\varphi = g, \text{ na } \Gamma_D \quad (4.58)$$

kjer  $n_D$  označuje število vozlišč na površini  $\Gamma_D$  z zaporedjem števil  $(1, 2, \dots, n_D)$  in so preostala vozlišča  $(n_D + 1, n_D + 2, \dots, n_n)$  z vrednostmi dane funkcije  $g$  v vozliščih in na  $\Gamma_D$ , določenimi z  $g_k$  ( $k = 1, 2, \dots, n_D$ ), funkcija

$$\varphi_D = \sum_{k=1}^{n_D} g_k N_k \quad (4.59)$$

izpolnjuje *Dirichletov* robni pogoj (4.58) v vozliščih na površini  $\Gamma_D$ . Ker globalne oblikovne funkcije, povezane z vozlišči  $n_D + 1, n_D + 2, \dots, n_n + n$ , kjer je  $n = n_n - n_D$ , torej zunaj  $\Gamma_D$ , očitno na tej površini izginejo, tako da je aproksimacija

$$\varphi^{(n)} = \varphi_D + \sum_{k=1}^{n_D+n} \varphi_k N_k \quad (4.60)$$

ustrezna za *Galerkinovo* metodo.

## 4.2 Teoretične osnove za obravnavo energetskega transformatorja

### 4.2.1 Matematični model izračuna dvodimenzionalnih elektromagnetnih polj

Statično oz. časovno neodvisno magnetno polje praktično ne vpliva na porazdelitev električnega toka v prevodniku. Iz tega dejstva sledi, da se lahko statično magnetno polje analizira neodvisno od tokovnega polja. Izvori statičnega magnetnega polja so lahko enosmerni tokovi ali permanentni magneti. Reševanje teh polj predstavlja najpreprostejše naloge v elektromagnetizmu, saj statična polja povzročijo elektrine v mirovanju ali enakomernem gibanju. Narava elektromagnetnih pojavov pa je mnogo bolj kompleksna, če se elektrina giblje z neenakomerno hitrostjo. V tem primeru je potrebno obravnavati celoten sistem *Maxwellovih* enačb in ni možno obravnavati električnega in magnetnega polja ločeno. Razlog za to je dejstvo, da je dinamično električno polje izvor magnetnega polja oz. da magnetodinamično polje inducira električno polje. V mnogih primerih pa je možno zanemariti tokove zaradi gibanja v elektromagnetnem polju in s tem je možno reducirati sistem *Maxwellovih* enačb. V tem primeru pravimo, da obravnavamo kvazistatično elektromagnetno polje [97].

Osnovna karakteristika kvazistatičnega elektromagnetnega polja je zanemaritev tokov zaradi gibanja. To pomeni, da lahko v vsakem trenutku v (4.1) zanemarimo člen  $\partial \mathbf{D} / \partial t$ .

Če na tem istem izrazu z zanemarjenim členom apliciramo matematično operacijo *rotor*, dobimo:

$$\nabla \times \nabla \times \mathbf{H} = \nabla \times \mathbf{J} = \nabla \times (\sigma \mathbf{E}) \quad (4.61)$$

Z uporabo (4.3) za linearne materiale, dobi enačba (4.61) naslednjo obliko:

$$\nabla(\nabla \mathbf{H}) - \Delta \mathbf{H} = -\Delta \mathbf{H} = \sigma \nabla \times \mathbf{E} \quad (4.62)$$

Upoštevajoč (4.2) dobimo enačbo, ki zadovoljuje vektor  $\mathbf{H}$  v kvazistatičnem elektromagnetnem polju v prevodnih materialih:

$$\Delta \mathbf{H} = \mu \sigma \frac{\partial \mathbf{H}}{\partial t} \quad (4.63)$$

S podobnim postopkom za vektorje  $\mathbf{E}$  in  $\mathbf{J}$  v kvazistatičnih poljih za primer reševanja problema brez prostih nabojev ( $\rho = 0$ ) dobimo enačbe:

$$\Delta \mathbf{E} = \mu \sigma \frac{\partial \mathbf{E}}{\partial t} \quad (4.64)$$

$$\Delta \mathbf{J} = \mu \sigma \frac{\partial \mathbf{J}}{\partial t} \quad (4.65)$$

V dobljeni sistem enačb lahko uvedemo še magnetni vektorski potencial  $\mathbf{A}$  ter skalarni potencial  $\varphi$ , kakor tudi za splošni sistem *Maxwellovih* enačb:

$$\mathbf{E} = -\nabla \varphi - \frac{\partial \mathbf{A}}{\partial t} \quad (4.66)$$

$$\mathbf{B} = \nabla \times \mathbf{A} \quad (4.67)$$

Z Lorentzovo umeritvijo pridemo do enačbe za magnetni vektorski in električni skalarni potencial v kvazistatičnih električnih poljih za materiale brez izgub:

$$\Delta \mathbf{A} = -\mu \mathbf{J}, \quad (4.68)$$

$$\Delta \varphi = -\frac{\rho}{\varepsilon}. \quad (4.69)$$

Osnovno vprašanje, ki se pri vpeljavi pojma kvazistatičnega polja pojavlja je, kdaj lahko določeno elektromagnetno polje obravnavamo kot kvazistatično. Odgovor na to vprašanje dobimo s primerjavo splošne rešitve sistema Maxwellovih enačb z rešitvami sistema kvazistatičnega polja. S tem postopkom dobimo pogoj kvazistatičnosti elektromagnetnega polja [97]:

$$J(\mathbf{r}, t) \gg \tau_{\max} \frac{\partial J(\mathbf{r}, t)}{\partial t} \quad (4.70)$$

pri čemer je s  $\tau_{\max}$  označen čas, ki je potreben, da bi se sprememba izvora polja zaznala v točki, določeni z vektorjem položaja  $\mathbf{r}$ . Pri tem se izvor nahaja v točki prostora, katero definira vektor položaja  $\mathbf{r}'$ .

V dinamičnih elektromagnetnih poljih se pogosto analizirajo časovno sinusno spremenljiva polja. V takih poljih se vse veličine polja menjajo sinusno po času na isti

krožni frekvenci  $\omega_0$ . Na primer, vektor električne poljske jakosti se v takšnem primeru lahko zapiše kot:

$$\mathbf{E}(\mathbf{r}, t) = E_x \cos[\omega_0 t + \psi_x(\mathbf{r})] \mathbf{a}_x + E_y \cos[\omega_0 t + \psi_y(\mathbf{r})] \mathbf{a}_y + E_z \cos[\omega_0 t + \psi_z(\mathbf{r})] \mathbf{a}_z \quad (4.71)$$

Analogno (4.71) lahko prikažemo tudi ostale veličine v sinusno spremenljivih poljih.

Kosinusna funkcija, ki opisuje časovne spremembe, se lahko zapiše kot realni ter kompleksni del funkcije:

$$A \cos(\omega_0 t + \psi) = \operatorname{Re}(A e^{j\psi} e^{j\omega t}) = \operatorname{Re}(\underline{A} e^{j\omega t}) \quad (4.72)$$

kjer kompleksno število  $\underline{A}$  predstavlja fazor.

Z uporabo tovrstnega načina prikazovanja skalarnih in vektorskih veličin sinusno spremenljivih elektromagnetnih polj, dobimo njihovo enostavnejši, t. i. fazorski prikaz. Tako na primer, za vektor električne poljske jakosti (4.71) velja:

$$\begin{aligned} \mathbf{E}(\mathbf{r}, t) &= E_x \cos[\omega_0 t + \psi_x(\mathbf{r})] \mathbf{a}_x + E_y \cos[\omega_0 t + \psi_y(\mathbf{r})] \mathbf{a}_y + E_z \cos[\omega_0 t + \psi_z(\mathbf{r})] \mathbf{a}_z = \\ &= \operatorname{Re} \left\{ \left[ E_x(\mathbf{r}) e^{j\psi_x(\mathbf{r})} \mathbf{a}_x + E_y(\mathbf{r}) e^{j\psi_y(\mathbf{r})} \mathbf{a}_y + E_z(\mathbf{r}) e^{j\psi_z(\mathbf{r})} \mathbf{a}_z \right] e^{j\omega t} \right\} = \operatorname{Re}(\underline{\mathbf{E}}(\mathbf{r}) e^{j\omega t}) \end{aligned} \quad (4.73)$$

Vpeljava fazorja omogoča, da se vse veličine preslikajo iz časovne v fazorsko domeno. Na ta način se eliminira časovna odvisnost v enačbi elektromagnetnega polja, ob tem pa vse veličine v fazorski domeni ostajajo samo funkcije prostorskih spremenljivk.

V sistemu *Maxwellovih* enačb se pojavljajo parcialni odvodi po času. V fazorski domeni se ta operacija prevede na množenje člena s kompleksnim številom  $j\omega$ , npr.:

$$\frac{\partial}{\partial t} \mathbf{E}(\mathbf{r}, t) = \operatorname{Re}(j\omega \underline{\mathbf{E}}(\mathbf{r}) e^{j\omega t}) \quad (4.74)$$

Sistem *Maxwellovih* enačb v fazorski domeni ima naslednjo obliko:

$$\nabla \times \underline{\mathbf{H}} = \underline{\mathbf{J}} + j\omega \underline{\mathbf{D}} \quad (4.75)$$

$$\nabla \times \underline{\mathbf{E}} = -j\omega \underline{\mathbf{B}} \quad (4.76)$$

$$\nabla \cdot \underline{\mathbf{D}} = \underline{\rho} \quad (4.77)$$

$$\nabla \cdot \underline{\mathbf{B}} = 0 \quad (4.78)$$

Prehod iz fazorske v časovno domeno se izvaja z inverznim postopkom glede na enačbo (4.73) in se prevede na množenje absolutne vrednosti vektorja v fazorski domeni s faktorjem  $\cos(\omega_0 t + \psi)$ .

#### 4.2.2 Matematični model izračuna dvodimenzionalnih temperaturnih polj

Temperatura  $T$  v katerikoli točki prostora predstavlja funkcijo koordinat točke  $(x, y, z)$  in časa  $t$ :

$$T = f(x, y, z, t) \quad (4.79)$$

Skupek temperatur v vseh točkah prostora v določenem časovnem trenutku se imenuje *temperaturno polje*. Za temperaturno polje, v katerem se temperatura spreminja s časom, pravimo, da je nestacionarno, za prenos toplote v takšnih pogojih pa se reče, da je nestacionaren. V primeru, če se polje s časom ne menja, pravimo, da je polje stacionarno, prav tako pa je prenos toplote v takšnih pogojih stacionaren. Prenos toplote se vrši na tri načine, ki bodo predstavljena v nadaljevanju [97].

##### *Kondukcija (prevajanje)*

Enačbi prevajanja toplote bazirajo na empiričnem zakonu in na principu ohranjanja energije. *Fourierov zakon* daje povezavo med tokom toplotne energije in temperaturnim poljem v materialu. Osnovo reševanja temperaturnega polja pri prenosu toplotne energije s prevajanjem definira *Fourierova enačba*, ki predstavlja diferencialno enačbo nestacionarnega prenosa toplote:

$$\nabla \cdot (\lambda \nabla T) - \rho c \frac{\partial T}{\partial t} + q_v = 0 \quad (4.80)$$

kjer je  $c$  specifična toplotna kapacitivnost,  $\rho$  specifična gostota materiala,  $\lambda$  koeficient prevajanja toplote,  $q_v$  količina toplote, ki jo daje izvor toplote ter  $t$  čas.

Postopek izračuna toplotnega polja otežuje dejstvo, da so specifična toplotna kapacitivnost, specifična gostota materiala ter koeficient prevajanja toplote odvisni od položaja opazovane točke in vrednosti temperature v tej točki.

##### *Konvekcija*

Prestop toplote s konvekcijo je matematično definiran z empiričnim izrazom:

$$q_p = \alpha(T_p - T_f) \quad (4.81)$$

kjer so  $q_p$  količina toplote, ki prehaja pravokotno na površino telesa,  $\alpha$  je koeficient prehoda toplote med telesom in medijem,  $T_p$  temperatura telesa ter  $T_f$  temperatura medija. Koeficient prehoda toplote  $\alpha$  je težko določiti zato, ker se pri njegovem izračunu uporabljajo enačbe, ki so dobljene na osnovi teoretične analize in katere vključujejo mnoge eksperimentalno določene koeficiente.

### Radiacija (sevanje)

Energija zračenja absolutno črnega telesa je odvisna od njegove temperature in je določena s Stefan-Boltzmannovim zakonom:

$$q_p = \sigma \varepsilon T^4 \quad (4.82)$$

kjer je  $q_p$  količina toplote, ki jo zrači (oddaja) absolutno črno telo in  $\sigma$  Stefan-Boltzmannova konstanta.

Dejanska telesa vedno emitirajo manjšo količino toplotne energije glede na absolutno črno telo. Izraz za energijo, katero telo izmenjuje z okolico, lahko zapišemo kot:

$$q_p = \varepsilon \sigma (T_p^4 - T_o^4) \quad (4.83)$$

kjer so  $\varepsilon$  koeficient emisije,  $T_p$  temperatura površine telesa ter  $T_o$  temperatura okolice.

Pri uporabi MKE metode za reševanje problema nestacionarnega temperaturnega polja se postavlja rekurzivna relacija med temperaturo elementa v trenutku  $t$  in trenutku  $t - \Delta t$ , s pomočjo katere se po iterativni poti računa odvisnost temperature od časa.

Osnovna enačba prenosa toplote je podana z izrazom (4.80). Rešitev te enačbe ob definiciji robnih pogojev daje vrednost temperature znotraj opazovanega področja. Da bi se lahko ta problem reševal z MKE je potrebno izpeljati integralno obliko enačbe (4.80), kar lahko izvedemo z variacijo funkcionala. Tako dobljena integralna oblika ima fizikalni pomen skupne toplotne energije sistema. Rešitev problema bazira na iskanju temperaturnega polja, za katerega bo toplotna energija sistema minimalna. Energijski funkcional ima v tem primeru obliko:

$$\Pi = \iiint_V \left\{ \frac{1}{2} \lambda (\nabla T)^2 - \left( q - \rho c \frac{\partial T}{\partial t} \right) \right\} dV \quad (4.84)$$

Funkcional  $\Pi$  ima za dvodimenzionalne probleme naslednjo obliko:



$$\Pi = \iint_s \left\{ \frac{1}{2} \lambda \left[ \left( \frac{\partial T}{\partial x} \right)^2 + \left( \frac{\partial T}{\partial y} \right)^2 \right] - \left( q - \rho c \frac{\partial T}{\partial t} \right) T \right\} dx dy \quad (4.85)$$

Temperatura  $T$  v katerikoli točki znotraj elementa je določena z naslednjo enačbo:

$$T = \mathbf{N} \mathbf{T}^e \quad (4.86)$$

kjer je  $N$  oblikovna funkcija in  $\mathbf{T}^e$  vektor z vrednostmi temperatur v posameznih vozliščih elementa.

### 4.2.3 Medsebojni vpliv elektromagnetnega in temperaturnega polja

#### 4.2.3.1 Direktni vpliv preko temperaturno odvisnih karakteristik materialov

Temperaturno polje vpliva na karakteristike vseh materialov, ki se uporabljajo v električnih napravah. S tem direktno ali indirektno vpliva tudi na njihovo elektromagnetno polje. Te temperaturne odvisnosti povzročajo nelinearne koeficiente v enačbah elektromagnetnega polja.

Električna prevodnost  $\sigma$  je zelo pomembna temperaturno odvisna karakteristika, ki direktno vpliva na električni tok v elektromagnetnih problemih. Njej inverzna veličina, električna upornost  $\rho$  se lahko aproksimira z naslednjim polinomom, ki je funkcija razlike temperature  $\Delta T$  [97]:

$$\rho = \rho_{\text{ref}} \left( 1 + \alpha_{\rho_{\text{ref}}} \Delta T + \beta_{\rho_{\text{ref}}} \Delta T^2 + \gamma_{\rho_{\text{ref}}} \Delta T^3 + \dots \right) \quad (4.87)$$

Za večino materialov se za zadovoljivo točnost lahko vzame samo linearni del enačbe (4.87). Tako se najpogosteje pri izračunih vzame naslednji izraz za električno upornost:

$$\rho = \rho_{\text{ref}} \left( 1 + \alpha_{\rho_{\text{ref}}} \Delta T \right) \quad (4.88)$$

#### 4.2.3.2 Direktni vpliv na izračun Joulovih izgub

Joulove izgube se pojavljajo vedno, ko po vodniku teče tok. Gostota Joulovih izgub lahko definiramo kot:

$$q_J = \frac{J^2}{\sigma} \quad (4.89)$$

Gostota izgub znotraj določenega volumna ali površine na povprečnem preseku prevodnika se definira kot integralni vpliv posamičnih KE preko celotne površine  $\Omega_e$ :

$$q_{J,\Omega_e} = \frac{1}{\Omega_e} \int_{\Omega_e} \frac{J^2}{\sigma} d\Omega \quad (4.90)$$

V kolikor je skupna gostota toka podana preko napetosti, lahko *Joulske* izgube zapišemo kot:

$$q_{J,\Omega_e} = \frac{1}{\Omega_e} \int_{\Omega_e} \sigma \left( \mathbf{E} + \frac{\partial \mathbf{A}}{\partial t} \right)^2 d\Omega \quad (4.91)$$

Za primer, da je električna prevodnost v analiziranem problemu temperaturno neodvisna, se *Joulske* izgube po MKE metodi računajo kot [97]:

$$q_{J,\Omega_e} = \frac{\sigma}{\Omega_e} \int_{\Omega_e} \left( \mathbf{E} + \sum_{k=1}^m N_k \frac{\partial \mathbf{A}}{\partial t} \right)^2 d\Omega \quad (4.92)$$

v primeru temperaturne odvisnosti, pa je potrebno upoštevati vpliv vsakega posameznega KE na velikost *Joulskih* izgub:

$$q_{J,\Omega_e} = \frac{1}{\Omega_e} \int_{\Omega_e} \left( \sum_{k=1}^m N_k \sigma_k \right) \left( \mathbf{E} + \sum_{k=1}^m N_k \frac{\partial \mathbf{A}}{\partial t} \right)^2 d\Omega \quad (4.93)$$

#### 4.2.3.3 Reševanje sklopljenega elektromagnetno-temperaturnega problema

Sklopljeni elektromagnetno-temperaturni problem predstavlja dva MKE problema (elektromagnetni in temperaturni) ter dve funkciji sklapljanja (izgube in temperaturno odvisnost materialov).

Teoretično je možno ob določenih zanemaritvah eliminirati sklopljenost elektromagnetnega in temperaturnega modela. Takšen način bi seveda dajal zadovoljive rezultate le v primeru, ko se eno polje spreminja zelo počasi oz. ko ga je možno obravnavati kot konstantnega glede na drugo polje ali ko je vpliv enega polja na drugo zelo majhen.

V splošnem primeru se sklopljeni problem rešuje tako, da se predpostavi, da je v določenem časovnem trenutku rešitev enega polja za vsa vozlišča vseh KE znana, medtem ko se drugo polje v tem trenutku računa (polje označeno z \*). Problem sklapljanja dveh polj se lahko takrat zapiše v naslednji obliki:

$$\begin{cases} F_E(\mathbf{E}, T^*) = 0 \\ F_T(\mathbf{E}^*, T) = 0 \end{cases} \quad (4.94)$$

kjer funkcija  $F_E$  predstavlja formulacijo elektromagnetnega problema:

$$\nabla(\nu \nabla \underline{\mathbf{A}}) - j\mu_0 \omega \sigma(T) \underline{\mathbf{A}} = -\mu_0 \sigma(T) \underline{\mathbf{E}} \quad (4.95)$$

ter funkcija  $F_T$  predstavlja formulacijo temperaturnega problema:

$$\nabla(\lambda \nabla T) - \rho c \frac{\partial T}{\partial t} + q_v = 0 \quad (4.96)$$

Pri izračunu tranzientnih režimov v sklopljenih magnetno-temperaturnih sistemih se pojavlja problem zato, ker so časovne konstante dinamičnih pojavov v magnetnem sistemu opazno manjše od časovnih konstant v temperaturnem sistemu. Na osnovi karakteristik predstavljenega problema se najbolj pogosto izbira kvazi-tranzientni algoritem reševanja. To pomeni, da se v enačbah, ki opisujejo elektromagnetno polje lahko zanemarijo odvodi temperature po času, ker imamo opravka z zanemarljivo malimi vrednostmi zaradi počasnih temperaturnih sprememb. Pri tem v postopku izračuna seveda niso zanemarjene temperaturne odvisnosti veličin, katere definirajo karakteristike materiala. Korekcija vrednosti temperaturno odvisnih veličin se izvaja pri vsaki spremembi temperature oz. vsakič, ko se izračuna nova vrednost temperature. Na ta način je do neke mere izvršeno ločevanje enačb, ki opisujejo edinstven naravni elektromagnetno-temperaturni problem na dva ločena: elektromagnetni in temperaturni. Da bi opisani postopek reševanja problema dosegel konvergenco, je potrebno v vsakem koraku izvesti iterativni postopek z namenom, da bi se doseglo, da izračunani rezultat temperaturnega polja ustreza tistemu, kar bi v opazovanem trenutku dalo toplotni izvor, ki bi generiral ravno to temperaturo.

### 4.3 Teoretične osnove za obravnavo plinskega odvodnika

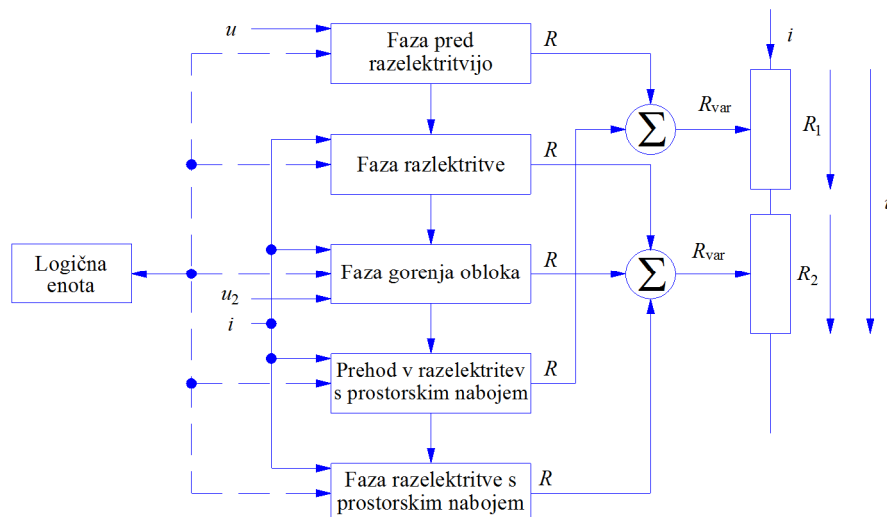
Plinski odvodnik (PO) prenapetosti je najpogostejši sestavni element prenapetostnih zaščit. Zahteve pri modeliranju PO so večplastne, saj mora model ponazoriti tako dinamični model procesa vžiga oz. začetka delovanja odvodnika, kot tudi fazo odvajanja toka oz. gorenja obloka. Razen tega mora zajeti tudi fazo gašenja el. obloka. Večplastnost fizikalne povezave predstavlja kompleksen problem, zato redki avtorji zajemajo v simulacijah vse procese. Pri modeliranju PO imamo v osnovi na voljo dva pristopa reševanja problema [107].

Prvi pristop je fizikalno-matematični model, ki je namenjen natančni obravnavi fizikalnih lastnosti, ki opisujejo oblok. Pri tem modelu predstavlja težavo določitev vhodnih parametrov po eni strani, po drugi strani pa nas bolj kot fizikalni pojavi zanimajo tokovne in napetostne karakteristike PO.

Drugi pristop – enostavnejši način obravnavanja omenjenih procesov – je uporaba energijske bilance, kjer ni potrebno upoštevati kompleksnih povezav, ampak le njihov vpliv na spremenljivke modela. To pomeni, določiti električnemu obloku dovedeno moč, kakor tudi oddano energijo na časovno enoto. Ta pristop je znan kot matematični model oz. model črne škatle ali "*Black box*" model. Ti modeli so dvopoli, definirani le z relacijami vhodnih in izhodnih veličin električnih parametrov (tok in napetost) in prostih parametrov, s katerimi določimo ustrezen odziv, kot je npr. bil izmerjen [107].

### 4.3.1 Matematični model plinskega odvodnika

Pri izdelavi modela PO je potrebno modelirati različne faze delovanja. Model je izveden kot spremenljiva upornost v črni škatli, ki ga krmilimo s posameznimi pod-bloki, kateri vsak zase predstavlja eno od fizikalnih dogajanj v plinskem odvodniku. Model z vsemi fizikalnimi fazami delovanja je prikazan na sliki 4.4 [107].



Slika 4.4: Faze delovanja modela PO

#### 4.3.1.1 Faza pred razelektritvijo

Ko je napetost med priključkoma odvodnika nižja od kritične oz. prebojne napetosti odvodnika  $U_{DC}$ , se plin v odvodniku obnaša kot dober izolator (z upornostjo reda nekaj  $G\Omega$ ). V primeru, ko presežemo prebojno napetost, se začnejo procesi pred razelektritvijo, in sicer elektroni začnejo pospeševati z višanjem napetosti. Ko dobijo dovolj kinetične

energije, ionizirajo atome in sprožijo sekundarno emisijo elektronov iz katode [88]. Ko napetost doseže vrednost dinamične napetosti razelektritve  $U_{\text{DYN}}$ , pride do razelektritve v plinu. Čas med trenutkom, v katerem dosežemo vžigno napetost  $U_{\text{DC}}$  in trenutkom, v katerem dosežemo dinamično napetost razelektritve  $U_{\text{DYN}}$ , imenujemo statistična zakasnitev razelektritve  $t_d$ :

$$t_d = aS^{-b} \quad (4.97)$$

kjer sta  $a$  [ $\text{s}^2/\text{V}$ ] in  $b$  interpolacijska koeficienta, ki ju je mogoče določiti s pomočjo meritev.  $S$  je strmina naraščanja napetosti čela [ $\text{V/s}$ ]. V tem podbloku se nahaja stikalo, ki je definirano kot upor s spremenljivo upornostjo  $R_s$ , s katero simuliramo nevzbujeno stanje in razelektritev:

$$R_s = \begin{cases} R_{s0}; & t < t_{\text{DC}} + t_d \\ R_{s0} \exp\left(-\frac{t - (t_{\text{DC}} + t_d)}{\tau_1}\right); & t \geq t_{\text{DC}} + t_d \\ R_{s1}; & R_s(t) \leq R_{s1} \end{cases} \quad (4.98)$$

kjer je:

$R_{s0}$  upornost odprtega stikala [ $\Omega$ ]

$R_{s1}$  upornost zaprtega stikala [ $\Omega$ ]

$\tau_1$  časovna konstanta zapiranja stikala [s]

$t_{\text{DC}}$  trenutek, v katerem dosežemo vžigno napetost  $U_{\text{DC}}$  [s]

#### 4.3.1.2 Faza razelektritve

Ko se plin med elektrodama ionizira, se vzpostavi prevodna pot med njima in pride do razelektritve (pramenasto tlenje). Tok skozi plinski odvodnik se večja, zato se večja tudi premer pramena, prav tako se večja sekundarna ionizacija plina. V končni fazi preide pramenasto tlenje v oblok. Naraščanje toka v fazi vžiga električnega obloka je možno zajeti s spremenljivo upornostjo po *Toeplerjevi* enačbi, prav tako je ta enačba uporabna v fazi gašenja obloka [89]:

$$R(t) = \frac{k_T d}{\int_{t_{\text{DC}} + t_d}^t i dt} \quad (4.99)$$

kjer je:

$i$  tok, ki teče skozi režo med elektrodama [A]

$k_T$  empirična *Toeplerjeva* konstanta [Vs/m]

$d$  razdalja med elektrodama [m]

Empirična konstanta  $k_T$  je odvisna od vrste oz. mešanice plinov, tlaka in razdalje med elektrodama [90]. Imenovalec v (4.99) predstavlja prenesen naboj (elektrone, ione) v določenem času skozi pramen.

Med fazo razelektritve tok med elektrodama plinskega odvodnika hitro narašča, upornost pa po enačbi (4.99) pada. Pri določenem toku pramen preide v oblok. Ta trenutek je v matematičnem modelu zaznamovan z upornostjo  $R_{ga}$ , ki predstavlja mejno vrednost upornosti med fazo razelektritve in obloka. Dobimo jo iz izvajanja in analize izračunov matematičnega modela plinskega odvodnika tako, da dobimo čim bolj zvezen prehod med obema fazama.

#### 4.3.1.3 Faza gorenja obloka

Pri določeni vrednosti toka, ki teče skozi nastali prevodni kanal v plinskem odvodniku, preide plamenasto tlenje v oblok. Za fazo gorenja obloka je v našem primeru uporabljen modificirani *Mayerjev* tip modela električnega obloka [91], [107]. V literaturi je včasih omenjen kot *Schavenmakerjev* model električnega obloka. Upornost (prevodnost) se spreminja po enačbi (4.100):

$$\frac{1}{g} \frac{dg}{dt} = \frac{d \ln(g)}{dt} = \frac{1}{\tau} \left( \frac{ui}{\max(U_{\text{arc}} |i|, P_0)} - 1 \right) \quad (4.100)$$

$$R = \frac{1}{g}$$

kjer je:

$\tau$  časovna konstanta, ki predstavlja razmerje med energijo v obloku in izgubami [s]

$P_0$  *Mayerjeva* konstantna moč oz. izgube obloka [W]

$U_{\text{arc}}$  *Cassiejeva* napetost, ki je konstantna pri velikih tokovih obloka [V]

*Mayrjeva* enačba izhaja iz predpostavke, da je električni oblok površinsko hlajen, kar pomeni konstantno odvajanje moči, zato je  $P_0$  konstanta, določimo pa jo na osnovi eksperimentalnih podatkov.

#### 4.3.1.4 Prehod iz obloka v samostojno razelektrenje s prostorskim nabojem

Pri znižanju toka skozi plinski odvodnik na neko določeno nizko vrednost, se katoda ohladi do mere, da se termična emisija, ki je bistvena v fazi gorenja obloka, konča. Posledično oblok ugasne. Tok ugasnitve obloka je  $I_{\text{ex}}$  in je kontrolna spremenljivka prehoda med fazo gorenja obloka in fazo samostojne razelektrenje s prostorskim nabojem. Ta trenutek označimo s  $t_{\text{ex}}$ . Prekinitev obloka lahko matematično opišemo podobno kot v fazi razelektrenje, le da stikalo najprej izklopimo, takoj za tem pa ponovno sklenemo. Spremenljivo upornost stikala za to fazo predstavimo kot:

$$R(t) = \begin{cases} R_{\text{arc}}(t); & t < t_{\text{ex}} \\ R_{\text{s10}} \left( \exp\left(-\frac{t-t_{\text{ex}}}{\tau_3}\right) - \exp\left(-\frac{t-t_{\text{ex}}}{\tau_2}\right) \right); & t \geq t_{\text{ex}} \end{cases} \quad (4.101)$$

kjer je:

$R_{\text{s10}}$  maksimalna upornost pri izklopu stikala [ $\Omega$ ]

$\tau_2$  časovna konstanta izklopa stikala [s]

$\tau_3$  časovna konstanta ponovne sklenitve stikala [s]

Ko upornost stikala po (4.101) doseže maksimalno vrednost, sprožimo spremembo upornosti razelektrenje po *Toeplerju*:

$$R(t) = \frac{k_{\text{Tag}} d}{\int_{t_{\text{ex}} + 4\tau_2}^t idt} \quad (4.102)$$

kjer je  $k_{\text{Tag}}$  [Vs/m] *Toeplerjeva* konstanta pri ponovni razelektrenji, ko je oblok že ugasnil in pride do ponovne razelektrenje.

Začetni čas integracije v (4.102) je trenutek, ko upornost stikala po (4.101) doseže maksimalno vrednost, tj. po približno štirih časovnih konstantah. Preneseni naboj ob prvi ponovni razelektrenji obravnavamo le za čas te razelektrenje. Skupna upornost tako v stacionarnem stanju pade toliko, da napetost znaša okrog 100 V, ko preidemo v fazo razelektrenje s prostorskim nabojem.

#### 4.3.1.5 Faza samostojne razelektrenje s prostorskim nabojem

Energija elektronov med ponovno razelektrenjijo ni več tolikšna, da bi sprožil termično emisijo elektronov iz katode tako, da je v tej fazi poglavitni mehanizem prevajanja bombardiranje katode s pozitivnimi ioni. Prevajanje v tej fazi ni učinkovito kot v fazi

obloka, saj je upornost višja, s tem pa tudi napetost ( $u_g \approx 100 \text{ V}$ ). Ko skupna upornost po (4.101) in (4.102) pade pod določeno vrednost (čas  $t_g$ ), sprožimo naraščanje upornosti po enačbi:

$$R(t) = R_g \left( 1 - \exp\left(-\frac{t - t_g}{\tau_4}\right) \right) \quad (4.103)$$

kjer je:

$R_g$     stacionarna vrednost upornosti v fazi razelektritve s prostorskim nabojem [ $\Omega$ ]

$\tau_4$     časovna konstanta naraščanja upornosti v prehodni fazi med ponovno razelektritvijo in razelektritvijo s prostorskim nabojem [s]

Vsi podbloki, ki so prikazani na sliki 4.4 in predstavljajo posamezne faze delovanja PO, so v programskem orodju Matlab Simulink predstavljeni kot en sam samostojen element [107].



## **5. APLIKACIJA OPTIMIZACIJSKIH ALGORITMOV NA RAZLIČNIH ELEMENTIH ELEKTROENERGETSKEGA OMREŽJA IN REZULTATI**

Pojem "elementi EEO" predstavlja širok nabor različnih naprav in elementov, ki se uporabljajo za različne namene. Posledično ima vsaka posamezna naprava ali element določene specifikacije, ki zahtevajo individualen pristop k reševanju njenega optimizacijskega problema. Ko govorimo o optimizaciji elementov EEO, je pri realizaciji algoritma za optimiranje ključnega pomena univerzalnost pri pristopu k reševanju optimizacijskega problema. V nadaljevanju so predstavljeni rezultati optimizacije različnih naprav oz. elementov EEO, ki jih po načinu teoretične obravnave lahko v glavnem umestimo v tri različne sklope, ki so predstavljeni v 4. poglavju.

### **5.1 Optimizacija geometrije podpornega kompozitnega izolatorja z uporabo diferenčne evolucije in genetskega algoritma**

#### **5.1.1 Uvod**

Osnovna funkcija izolatorjev je električna ločitev prevodnih od ozemljenih delov naprav ter mehansko pritrjevanje opreme in vodnikov, ki imajo različne potenciale [2]. Izolatorje najdemo povsod v sistemu in posledično je zanesljivost obratovanja EEO od njih zelo odvisna. Zaradi tega je pomembno, da so posamezni izolacijski elementi dobro načrtovani in zanesljivi pri svojem delovanju. Njihova zanesljivost je med drugim zelo odvisna od vrednosti električnega polja v kritičnih točkah obravnavanega izolacijskega sistema, zato je električna poljska jakost eden od pomembnejših kriterijev pri načrtovanju izolatorjev.


## 5.1.2 Predstavitev objekta

Obravnavani podporni kompozitni izolator (PKI), ki je prikazan na sliki 5.1 a, je namenjen za vgradnjo v nadzemne vode. Sestavljen je iz dveh izolacijskih materialov, kjer eden zadovoljuje električne zahteve (oplaščenje), drugi pa mehanske (nosilno jedro). Nasprotno pa so klasični keramični in stekleni izolatorji sestavljeni iz enega samega izolacijskega materiala, ki mora zadovoljevati tako električne kot tudi mehanske zahteve.

Material, ki je uporabljen za oplaščenje izolatorja, je iz silikonske gume. Razlog za uporabo materiala z lastnostmi gume je predvsem mehanski, saj ima material nosilnega jedra lastni razteznostni koeficient. Ker ne želimo mehanskih poškodb izolatorja zaradi raztezanja, mora biti oplaščenje iz materiala, ki lahko sledi tem spremembam. Prednosti silikonske gume so fleksibilnost tudi pri nizkih temperaturah, velika mehanska odpornost, odpornost na različne zunanje dejavnike (UV sevanje, visoke temperature, onesnaženost v industrijskih okoljih), odbojnost vode (hidrofobičnost) ter dobra električna izolacijska sposobnost [92].

Nosilno jedro PKI iz epoksidnih ali poliestrskih smol je ojačano s steklenimi vlakni. Le-to je prekrito z zaščitno oblogo, ki je izdelana s centrifugiranjem silikonske gume neposredno na palici [92]. V splošnem so na takšno palico kasneje nameščena predhodno izdelana izolatorska rebra iz silikona.


Kompozitni izolatorji so na obeh koncih opremljeni s kovinskimi končniki (slika 5.1 a), ki prenašajo mehansko obremenitev na jedro izolatorja [93]. Konkretni primer podpornega kompozitnega izolatorja, ki je v nadaljevanju predmet obravnave, ima zgradbo, ki je predstavljena na sliki 5.1 b.



Slika 5.1: a) Fotografija PKI b) Sestavni deli PKI in predstavitev parametrov za optimizacijo geometrije

### 5.1.3 Analiza električnega polja z uporabo orodja EleFAnT2D

Izolator na sliki 5.1 a je grajen za nazivno napetost 24 kV in glede na veljavne standarde s področja preskušanja tovrstnih izdelkov, je zanj predvidena preskusna napetost 125 kV. Geometrija izolatorja je osnosimetrična, kar nam omogoča izračun električnega polja z uporabo programskega orodja EleFAnT2D [94]. Pred izračunom in analizo polja obravnavanega problema je potrebno najprej izdelati model PKI, torej natančno definirati geometrijo, vrsto materialov oz. njihove dielektrične konstante ter robne pogoje. Upoštevajoč zahtevo standardov za preskušanje, na zgornjem končniku definiramo *Dirichletove* robne pogoje (125 kV), na spodnjem pa 0 V [95]. Določitvi robnih pogojev in definiciji materialov sledi diskretizacija opazovanega področja problema. Ta del programske rešitve je pri vseh numeričnih metodah najbolj kritičen, saj mora zadovoljiti različne pogoje, od katerih je najpomembnejši univerzalnost glede geometrije. Mrežni generator nam celotno področje problema razdeli na neprekrivajoče KE, ki so v primeru osnosimetričnih problemov liki (slika 5.2 a). Po končani diskretizaciji področja sledi še izračun potenciala v posameznih vozliščih KE in na osnovi le-tega tudi električne poljske jakosti (slika 5.2 b) [3].



Slika 5.2: a) Diskretizirano področje izolatorja z okolico b) Električno polje, izračunano pri preskusni napetosti 125 kV

Področja, ki so na sliki 5.2 b obarvana z rdečo barvo, so najbolj obremenjena. Vrednost polja v eni od najbolj obremenjenih točk (ta se nahaja na meji plašča z okoliškim zrakom) znaša približno 2,6 MV/m, kar pa je relativno blizu prebojni trdnosti zraka, ki znaša 3 MV/m. Te vrednosti po rezultatih sodeč ne dosegamo, vendar s stališča zanesljivejšega obratovanja izolatorja si želimo, da so vrednosti polja v najbolj obremenjenih točkah nizke, kolikor je to le mogoče. Zaradi tega bomo pri poskusu znižanja vrednosti polja parametrično zapisali dele geometrije izolatorja (palico iz steklenih vlaken, oplasčenja ter reber iz silikonske gume – slika 5.1 b) in s

spreminjanjem parametrov poiskali tisto konfiguracijo, pri katerih so vrednosti polja v kritičnih točkah najnižje.

Po izvedbi parametričnega zapisa geometrije izolatorja smo določili meje parametrov, znotraj katerih je njihovo spreminjanje dovoljeno. Parameter  $p_1$  smo omejili na interval  $[0;3]$  mm,  $p_2$  na  $[0;1,5]$  mm,  $p_3$  na  $[-2;10]$  mm,  $p_4$  na  $[-1;1]$  mm in  $p_5$  na  $[0;2]$  mm. S parametrom  $p_1$  spreminjamo polmer nosilne palice izolatorja, s  $p_2$  pa debelino nanosa iz silikonske gume oz. plašča. S parametrom  $p_3$  spreminjamo dolžino reber, kjer so meje spreminjanja tega parametra postavljene tako, da dovoljujemo tudi skrajšanje le-teh, vendar je to skrajšanje ob upoštevanju nastavljenih spodnje meje parametra relativno majhno, saj dolžine reber ne smemo preveč zmanjšati, ker lahko s tem posledično skrajšamo plazilno razdaljo izolatorja na vrednost, ki je pod dovoljeno. Zadnja dva, parametra  $p_4$  in  $p_5$  vplivata na spremembo debeline reber.

#### 5.1.4 Kriterijska funkcija

Kot je že bilo omenjeno, je eden pomembnejših kriterijev pri načrtovanju stikalnih naprav, med drugim tudi izolatorjev, dimenzioniranje le-teh glede na električno poljsko jakost. Tako je pri reševanju predstavljenega problema kriterij optimizacije vrednost električne poljske jakosti v najbolj obremenjeni točki, naš cilj pa je minimizirati to vrednost na najnižjo možno raven. Pri obravnavi realnih tehniških problemov običajno nimamo v naprej pripravljenih KF, zato jih moramo za vsak posamezni primer ustrezno definirati. To je seveda poleg izbire ustrezne optimizacijske metode zelo pomembno opravilo. Način priprave KF je odvisen od vrste problema, ki ga rešujemo. V osnovi lahko pripravimo dve vrsti kriterijev, in sicer kriterij *najboljšega ujemanja* ali kriterij *minimuma*, kjer [26]:

- kriterij *najboljšega ujemanja* (slika 5.3 a) zahteva, da se rešitev  $x$  čim bolj približa referenčni vrednosti, pri kateri najbolj zadovolji KF:  $f(x) = 1$  in
- kriterij *minimum* (slika 5.3 b), ki zahteva da rešitev  $x$  leži čim nižje in s tem bolje zadovoljuje kriterij.

Enostaven način za zapis obeh vrst KF je uporaba naslednjega izraza, kjer sta obe strani pridružene zvončaste funkcije opisani z eno od funkcij:


$$f(x) = \begin{cases} e^{-l(x-m)^2} & x \leq m \\ e^{-d(x-m)^2} & x > m \end{cases} \quad (5.1)$$

kjer je  $m$  vrednost, pri kateri ima funkcija relativno vrednost 1. Oblikovalec funkcije ima nalogo določiti, v katerem področju naj določena rešitev 90 % zadovolji kriterij. Za to je

potrebno izračunati konstanti  $l$  in  $d$  (5.2), ki bosta zagotavljali, da bo pri  $x_{190\%}$  in  $x_{d90\%}$  funkcijska vrednost tej zahtevi tudi ustrezala (slika 5.3 b):


$$\begin{cases} l = \frac{\ln(0,9)}{-(x_{190\%} - m)^2} \\ d = \frac{\ln(0,9)}{-(x_{d90\%} - m)^2} \end{cases} \quad (5.2)$$

Cilj optimizacije, s katero začetni model PKI izboljšujemo skozi iterativni proces, je doseganje optimalne rešitve glede na v naprej pripravljene kriterij. V našem primeru težimo k minimizaciji električne poljske jakosti, njene vrednosti pa lahko predstavimo indirektno z uporabo pridružene zvončaste funkcije (slika 5.3 b). S to funkcijo je mogoče v relativnih vednosti izraziti, kako množica parametrov zadovolji kriterij.



Slika 5.3: Pridruženi zvončasti funkciji: a) kriterij najboljšega ujemanja b) kriterij *minimum*

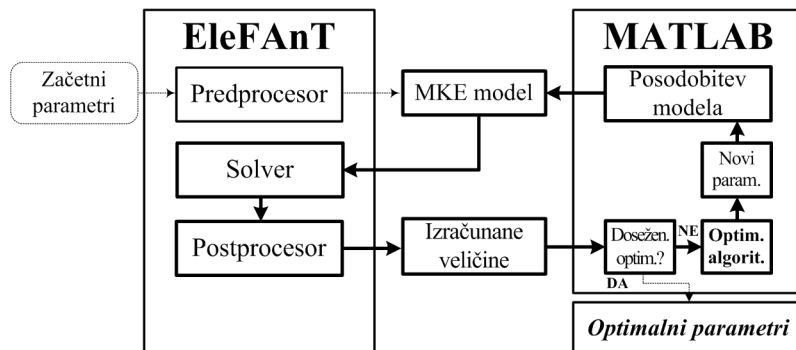
Pri pripravi KF (slika 5.4) smo definirali 2,2 MV/m kot želeno vrednost. KF je nastavljena tako, da zavzema vrednosti med 0 in 1. Bližje kot smo vrednosti 1, to pomeni, da smo bližje želeni vrednosti. Ker pa želimo KF minimizirati, smo v postopku optimizacije dejansko upoštevali vrednost  $1-f(E)$ .



Slika 5.4: Oblika KF za optimizacijo geometrije PKI

### 5.1.5 Algoritem za načrtovanje

V preteklosti je potekalo načrtovanje izolacijskih elementov na tak način, da je bila v prvi fazi izbrana oblika in materiali izdelka. Ta izbira je temeljila predvsem na izkušnjah načrtovalca oz. na podlagi preteklih izkušenj. V drugi fazi je sledilo modeliranje izdelka in izračuni z namenom preverjanja skladnosti izdelka s predpisanimi kriteriji. V tretji fazi so sledile korekcije modela in ponovni izračuni, in sicer toliko časa, dokler izdelek ni bil skladen s kriteriji. Slabost tega postopka je bila predvsem njegova velika časovna zahtevnost, ki pa je bila posledica priprave novega modela ob vsaki spremembi parametrov [3]. Novi koncepti načrtovanja izdelkov pa zahtevajo načrtovanje v čim krajšem času. Za izpolnitev te zahteve se danes poslužujemo računalniškega načrtovanja izdelkov v povezavi z optimizacijskimi algoritmi. Povezava je predstavljena v algoritmu za načrtovanje na sliki 5.5, ki se sestoji iz parametrično zapisanega modela, avtomatskega generatorja mreže, solverja programskega orodja za izračun polja po MKE in izbranega optimizacijskega algoritma. Prednost takšnega algoritma je v tem, da lahko samostojno posodablja model z novimi parametri, celoten postopek načrtovanja pa ne zahteva intervencije uporabnika. Algoritem prav tako omogoča implementacijo poljubne stohastične optimizacijske tehnike. V konkretnem primeru sta uporabljena algoritma DE in GA. Polje izolatorja smo računali s programskim orodjem EleFAnT2D, oceno kvalitete rešitev pa smo določali s pomočjo *minimum* KF, ki je predstavljena na sliki 5.4.



Slika 5.5: Grafični prikaz algoritma za načrtovanje in optimizacijo

### 5.1.6 Rezultati optimizacije

Začetni model PKI s parametrično zapisano geometrijo sta optimizacijska algoritma v svojem evolucijskem procesu spreminjala in iskala čimbolj ugodno konfiguracijo. Rezultat optimizacije je nabor optimalnih parametrov  $p_1$  do  $p_5$  (tabela 5.1), ki smo jih dobili pri velikosti populacije  $NP = 25$  in naslednjih krmilnih parametrov – GA: verjetnost križanja = 0,8; verjetnost mutacije = 0,01 in DE:  $F = 0,5$ ;  $Cr = 0,8$  in  $st. = 7$  (DE/rand/1/bin). Dobljene optimalne vrednosti parametrov definirajo geometrijo izolatorja, ki omogoča najbolj ugodno porazdelitev električnega polja. Vrednosti  $h_1$  in  $h_2$


predstavljata izhodiščni točki, ki se nahajata pri korenu posameznega izolatorskega rebra, in sicer točko nad ter pod rebrom.

Tabela 5.1: Rezultati optimizacije geometrije PKI

Parameter (mm)	$p_1$	$p_2$	$p_3$	$p_4$	$p_5$
Začetna vrednost	19	22,50	60	$h_1$	$h_2$
Optimalna vrednost (DE)	22	23,97	63,94	$h_1+0,91$	$h_2+2$
Optimalna vrednost (GA)	21,96	24	63,84	$h_1+1$	$h_2+2$

Z optimirano geometrijo PKI smo dosegli znižanje električne poljske jakosti v najbolj obremenjeni točki z 2,6 MV/m (pri začetnih vrednostih parametrov) na 2,21 MV/m z uporabo algoritma DE ter na 2,22 MV/m z uporabo GA.


Konvergenco optimizacijskega postopka prikazujeta sliki 5.6 a in 5.6 b, kjer je v vsaki generaciji prikazana vertikalna linija, ki kaže razpon med vrednostma KF za najboljši in najslabši osebek v populaciji. Črna krivulja po drugi strani označuje povprečno vrednost KF vseh osebkov v trenutni generaciji in na sliki 5.6 a prikazuje hitro konvergenco algoritma DE proti optimumu. Prav tako je vidno, da se raznolikost populacije skozi evolucijo zmanjšuje. V trenutku, ko je konvergenca dosežena, ugotovimo, da je celotna populacija uniformna. To je posledica strogega mehanizma selekcije algoritma DE, ki omogoča vstop v populacijo samo tistim potomcem, ki so boljši od svojih staršev. Za GA na sliki 5.6 b velja enako kot za DE, da se najboljši osebek v trenutni generaciji nikoli ne zamenja, razen če algoritem najde boljšega kandidata za rešitev. Po drugi strani pa GA dovoljuje vstop v populacijo tudi slabim potomcem, kar ima za posledico veliko raznolikost populacije na koncu evolucije.



Slika 5.6: Najboljša, najslabša in povprečna vrednost KF v posamezni generaciji za a) DE in b) GA

Spremembe vrednosti KF najboljšega osebkov v populaciji lahko na grafih spremljamo okoli 2/3 evolucije, medtem ko majhne spremembe v kasnejših generacijah niso več vidne. Zaradi tega so na slikah 5.7 a za DE in 5.7 b za GA prikazane razlike v vrednostih


KF med trenutno najboljšim osebkom v opazovani generaciji in njegovim predhodnikom.



Slika 5.7: Sprememba vrednosti KF najboljšega osebk za a) DE in b) GA

Kot je vidno na sliki 5.7 a, je algoritem DE našel zadnjo izboljšavo oz. je dosegel minimum KF po 99 generacijah. Glede na sliko 5.7 b vidimo, da ima v tem primeru GA počasnejšo konvergenco, saj je dosegel svoj minimum po 106 generacijah. Pri tem je potrebno poudariti, da oba algoritma nista enako dobro zadovoljila KF in da se je po večkratni ponovitvi optimizacijskega postopka algoritem DE vedno bolje izkazal, pri tem pa je vedno dosegel isto rešitev, medtem ko je GA običajno prispel v njeno neposredno okolico.

Ko je dosežena konvergenca optimizacijskega postopka, se ustavi tudi spreminjanje parametrov najboljšega osebk. Trajektorije parametrov najboljšega osebk skozi evolucijo so predstavljene na sliki 5.8.



Slika 5.8: Trajektorije najboljšega osebk za a) DE in b) GA

Najboljši osebek na koncu evolucije vsebuje optimalne parametre, ki pa za oba algoritma niso identični. Kot vidimo v tabeli 5.1 imamo manjšo razliko v vrednostih določenih parametrov. Razlog za to je v GA, ki je sicer konvergirala proti optimumu, vendar se je ustavila v njegovi neposredni bližini.




## 5.2 Izboljšanje natančnosti termičnega MKE modela transformatorja z uporabo optimizacije

### 5.2.1 Uvod

Transformatorji so eni izmed najzanesljivejših elementov elektroenergetskega sistema [96], vendar pa zahtevajo dosledno načrtovanje ter pozornost pri določanju termičnih obremenitev njihovih sestavnih delov. Temperaturna slika transformatorja je zelo pomembna, saj nadtemperature povzročajo zniževanje življenjske dobe transformatorja ali poškodbe izolacije, kar pa s časom vodi k resnejšim okvaram.

Razporeditev temperaturnega polja v transformatorju lahko določimo s pomočjo ustreznega MKE modela. Izdelava takšnega modela seveda zahteva podatke o geometriji naprave, virih toplote in robne pogoje. Karakteristike materialov, ki imajo bistven vpliv na natančnost modela, so prav tako zahtevane. Le-te pa so zelo pogosto težko merljive ali nemerljive. Posledično velikokrat uporabljamo podatke, ki jih dobimo bodisi od proizvajalca ali iz različnih virov. Seveda je točnost teh podatkov tudi vprašljiva, kar se lahko v končni fazi izrazi v nezadovoljivi natančnosti modela v primerjavi z dejansko napravo (slika 5.9). Da bi dosegli čim boljše ujemanje med MKE modelom in dejansko napravo, je potrebno omenjene karakteristike natančno določiti.



Slika 5.9: Fotografija merjenja - trifazni 2.4 kVA transformator

### 5.2.2 Predstavitev matematičnega modela

Za modeliranje termičnega procesa uporabljamo MKE modele, ki opisujejo sklopljeno elektromagnetno in temperaturno polje [97] – [100]. Sklopljeno elektromagnetno-temperaturno polje dejansko predstavlja dva ločena MKE problema (elektromagnetno in

temperaturno polje) ter dve funkciji sklapljanja, in sicer izgube ter temperaturno odvisnost materialov. Osnovni kriterij, ki omejuje obremenitev transformatorja in vpliva na njegovo življenjsko dobo, je temperatura [101]. Posledično je natančna določitev razporeditve temperaturnega polja zelo pomembna in je možna z uporabo natančnega MKE modela. Za reševanje predstavljenega problema je uporabljeno programsko orodje FLUX2D [102], podrobnejša teoretična predstavitev MKE modela transformatorja pa je podana v 4. poglavju.

### 5.2.3 Kriterijska funkcija

Cilj izboljšave natančnosti matematičnega modela je doseganje čim boljšega ujemanja modela z dejansko napravo. Zaradi tega določitev KF  $q$  bazira na razlikah med z modelom izračunanimi in na dejanski napravi izmerjenimi temperaturami. Tako množico izmerjenih in izračunanih vrednosti temperatur v posameznih diskretnih trenutkih zapišemo kot vektor napake  $\mathbf{e}_{Pi}$ , oceno napake pa je možno določiti s pomočjo Evklidske norme ali njene skalirane različice, imenovane *root-mean-square* (RMS) norma [103], [104]. Določimo jo tako, da izračunamo kvadratni koren produkta vektorja napake  $\mathbf{e}_{Pi}$  s samim seboj, vendar z aplicirano matematično operacijo *transponiranje*. Dobljena vrednost je še deljena z dimenzijo vektorja [ $1 \times n$ ], kjer je  $n$  število diskretnih vrednosti oz. odtipkov temperature:

$$\|\mathbf{e}_{Pi}\|_{RMS} = \left( \frac{1}{n} \mathbf{e}_{Pi}^T \mathbf{e}_{Pi} \right)^{\frac{1}{2}} \quad (5.3)$$

RMS norma predstavlja efektivno napako oz. določeno mero med izmerjeno in izračunano vrednostjo oz. v našem primeru med izmerjeno in izračunano vrednostjo temperature. Ker gre za večje število odtipkov v določenem časovnem okviru, zapišemo vektor napake kot:

$$\mathbf{e}_{Pi} = \mathbf{T}_{m, Pi} - \mathbf{T}_{c, Pi} \quad (5.4)$$


ki ga dobimo tako, da izračunamo razliko med istoležnimi vrednostmi izmerjene temperature  $\mathbf{T}_{m, Pi}$  ter izračunane  $\mathbf{T}_{c, Pi}$ , in sicer za  $i$ -to točko P na transformatorju. V obravnavanem primeru je izračun temperature narejen z variabilnim korakom integracije, kar pomeni, da se dimenzija vektorja  $\mathbf{e}_{Pi}$  od izračuna do izračuna razlikuje. Zaradi tega ocene napake med seboj niso primerljive in jih je potrebno normirati. To je bistvenega pomena, če želimo definirati uporabno KF, ki bo vodila optimizacijski algoritem proti globalnemu optimumu. Normiranje je izvedeno glede na RMS normo izmerjene temperature  $\mathbf{T}_{m, Pi}$ , ker vsakemu posameznemu elementu vektorja najprej odštejemo vrednost  $\min\{\mathbf{T}_{m, Pi}\}$ , tj. temperaturo okolice. Tako je dobljena razlika

$$\mathbf{m}_{P_i} = \mathbf{T}_{m, P_i} - \min\{\mathbf{T}_{m, P_i}\} \cdot \mathbf{I} \quad (5.5)$$

kjer je  $\mathbf{T}_{m, P_i}$  vektor, ki vsebuje vrednosti temperature izmerjene v točki  $P_i$ ,  $\mathbf{I}$  pa je stolpčni vektor, katerega členi so enice. RMS norma izmerjene temperature  $\|\mathbf{m}_{P_i}\|_{RMS}$  je izračunana analogno izrazu (5.3). Tako je normirana RMS norma (NRMS) definirana z izrazom (5.6):

$$\|\mathbf{e}_{P_i}\|_{NRMS} = \frac{\|\mathbf{e}_{P_i}\|_{RMS}}{\|\mathbf{m}_{P_i}\|_{RMS}} \quad (5.6)$$

Glede na dejstvo, da je RMS norma proporcionalna površini pod opazovano krivuljo (slika 5.10), je interpretacija NRMS norme preprosta. Na primer, če je vrednost NRMS norme 0,05, potem površina med izmerjeno in izračunano krivuljo (angl. *Area Between Exact and the Obtained Solution* – ABEOS) predstavlja 5 % površine pod izmerjeno krivuljo (angl. *Area Under the Exact Solution* – AUES). Izmerjeni odziv je v tem kontekstu zmanjšan za svojo najmanjšo vrednot, kot je prikazano v (5.5).



Slika 5.10: Predstavitev povezave med izrazoma ABEOS in AUES ter NRMS normo

KF  $q_{P_i}$  sedaj definirana kot:

$$q_{P_i} = \|\mathbf{e}_{P_i}\|_{NRMS} \quad (5.7)$$

in nam podaja oceno o ujemanju izračunane in izmerjene temperature v točki  $P_i$ .

V konkretnem primeru smo opazovali dve točki, in sicer določeno točko  $P_1$ , ki se nahaja na jedru transformatorja in točko  $P_2$ , ki se nahaja na navitju. Tako imamo dve KF  $q_{P_1}$  in  $q_{P_2}$ , ki ju želimo simultano minimizirati. To lahko dosežemo tako, da združimo oba kriterija v eno KF  $q$ , in sicer tako, da obtežimo oba kriterija in ju seštejemo [26]:

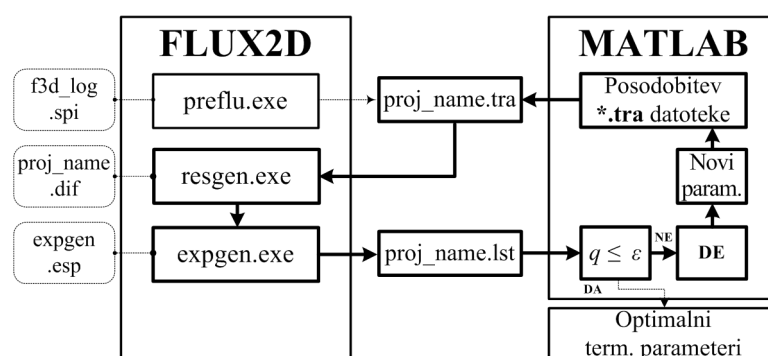
$$q = w_1 q_{P_1} + w_2 q_{P_2} \quad (5.8)$$

Ker sta oba kriterija enakovredna, nastavimo enako vrednost uteži  $w_1$  in  $w_2$ , npr.  $w_1 = w_2 = 0,5$ .

## 5.2.4 Postopek določanja parametrov termičnega MKE modela transformatorja

Postopek izdelave modela transformatorja zahteva natančne vhodne podatke, kot so geometrija transformatorja, določanje toplotnih virov in robnih pogojev. Te podatke ni težko pridobiti, nasprotno pa velja, kadar govorimo o karakteristikah materialov oz. v konkretnem primeru o termičnih parametrih modela. Njihove okvirne vrednosti pridobimo v raznih katalogih ali drugih virih [105], vendar je dejanska izbira pogosto vprašljiva, zato je zaželeno, da jih natančneje določimo.

Algoritem za določitev parametrov je prikazan na sliki 5.11. Zaporedje korakov v algoritmu je prikazano z odebeljeno črto. Proces se prične s shranjevanjem podatkov modela, katere vnašamo v okno programskega orodja FLUX, shranjujejo pa se v datoteko *f3d\_log.spi*. Datoteke, ki so grafično predstavljane s črtkano črto, so ključne datoteke, v katere so shranjene vse informacije, ki so potrebne za proces računanja z modelom. Na osnovi datoteke *f3d\_log.spi* predprocesor orodja FLUX kreira datoteko *proj\_name.tra*, ki predstavlja modela transformatorja. Ta datoteka vsebuje podatke o karakteristikah uporabljenih materialov, vire, robne pogoje in koordinate vozlišč KE oz. mreže. Parametri izračuna, kot so korak integracije in čas simulacije, so definirani v datoteki *proj\_name.dif*, katero uporablja *solver* – jedro orodja FLUX. Ko je izračun solverja zaključen, se aktivira postprocesor *expgen.exe* za prikaz izračunov. Veličine, ki naj bi bile prikazane (v našem primeru temperatura), so določene v datoteki *expgen.esp*, njihove vrednosti pa so izpisane v datoteko *proj\_name.lst*. Natančnost teh rezultatov je nato ovrednotena glede na izmerjeno temperaturo na način, da se oceni vrednost KF  $q$ .



Slika 5.11: Grafična predstavitev algoritma za določitev parametrov

Boljše kot je ujemanje izmerjenih in izračunanih vrednosti, tem manjša je vrednost KF  $q$ . Če ujemanje ni zadovoljivo, se zaporedje korakov po sliki 5.11 ponovno izvede, in sicer tako da se najprej posodobi model transformatorja. To v praksi pomeni, da optimizacijski algoritem generira nov nabor parametrov, posodobi model in začne nov MKE izračun. Iskanje optimalnih termičnih parametrov je izvedeno v obliki iterativnega postopka posodabljanja modela z novimi termičnimi parametri, tranzientnim izračunom

temperature in oceno odstopanja med izmerjeno in izračunano temperaturo, in sicer za vsak nabor parametrov posebej.

Avtomatizacija procesa računanja v orodju FLUX je realizirana v programskem orodju MATLAB, v ta namen pa sta izdelani dve "batch" datoteki. Vsebina datotek je prikazana na dveh slikah, in sicer na sliki 5.12 je predstavljena vsebina, ki omogoča avtomatizacijo solverja ter na sliki 5.13 vsebina, ki omogoča avtomatizacijo postprocesorja. Slika 5.13 pri tem prikazuje le del vsebine oz. zadnji del datoteke, saj je prvi del identičen vsebini, ki je prikazana na sliki 5.12.

```
ECHO OFF
@SET TERMBQ=C:\Cedrat\Flux2d_760\TERMBQ.V2
@SET PLOTBQ=C:\Cedrat\Flux2d_760\PLOTBQ.V2
@SET LECGRA=LECGRA
@SET CAO_DEFLAN=2
@SET MEMDYN=OUI
@SET MEMSIZN=80000000
@SET MEMSIZC=160000000
@SET MEMSIZN3=800000000
@SET MEMSIZC3=160000000
@SET CAOLIG=50
@SET CAOBKCO=BLACK
@SET TYPFMT=1
@SET USER=flux
@SET TITBLKU=
@SET F3D_APPLI=PREFLU
@SET F3D_DIMAPP=2
@SET DLOGDATA=C:\Cedrat\Flux2d_760\DATABASE
@SET PREFLU2D=f3d330_dyn
@set PATH=C:\Cedrat\Flux2d_760;C:\Cedrat\Flux2d_760\dll;
%systemroot%\system32;%systemroot%;%systemroot%\system32\wbem;
C:\program files\ati technologies\ati control panel;
C:\ProgramFiles\MATLAB\bin\win32;
C:\Cedrat
@SET MATERI=
@SET LM_LICENSE_FILE=C:\Cedrat\Flexlm7.2\F2d_030528.dat
@SET BATCH=YES
@SET CAO_INPUT=LAB1.DIF
START/W RESGEN
```

Slika 5.12: Vsebina datoteke *resgen.bat*


```
ECHO OFF
@SET BATCH=YES
@SET CAO_INPUT=expgen.esp
START/W EXPGEN
```

Slika 5.13: Del vsebine datoteke *expgen.bat*

V primeru optimizacije PKI smo imeli opravka z reševanjem direktnega problema, saj smo z definiranjem vseh atributov MKE modela, z njegovim reševanjem dejansko dobili rešitev Maxwellovih enačb, ki pa je unikatna oz. edinstvena za dane pogoje izračuna. Nasprotno je pri reševanju inverznega problema, saj je v tem primeru rešitev znana, iščemo pa pogoje, pri katerih je bila dobljena. Za razliko od direktnih problemov, kjer obstaja unikatna rešitev Maxwellovih enačb, lahko pri inverznih problemih najdemo množico različnih modelov, ki bodo zelo podobno simulirali obnašanje opazovane

naprave [106]. Še več, merjene veličine vedno vsebuje določeno napako meritve. Zaradi tega je pravo rešitev inverznega problema včasih težko zagotoviti. Tak primer je identifikacija termičnih parametrov modela transformatorja, pri katerem moramo poiskati množico parametrov modela, pri kateri se bo ta obnašal tako, kot je bilo izmerjeno na dejanskem objektu.

Problem identifikacije termičnih parametrov transformatorja smo reševali z uporabo komercialnega programskega orodja FLUX. Raznolikost problemov in orodij, ki so na voljo, je privedla do razvoja *univerzalnega algoritma za načrtovanje in identifikacijo parametrov* (slika 5.14). Le-ta je orientiran predvsem na uporabo različnih programskih orodij za posredno cenitev KF optimizacijskega problema in odprt za implementacijo poljubnih (evolucijskih) optimizacijskih tehnik, kar omogoča široko namembnost. Poleg načrtovanja novih ter optimizacije obstoječih elementov in naprav EEO je zmožen prevzeti vlogo orodja za reševanje inverznih problemov, in sicer identifikacijo parametrov modela modelirane naprave/elementa oz. njegovo uglaševanje.



Slika 5.14: Univerzalni algoritem za načrtovanje in identifikacijo parametrov

### 5.2.5 Rezultati optimizacije


Rezultat optimizacije je nabor optimalnih termičnih parametrov, ki je predstavljen v tabeli 5.2 in je bil dosežen pri naslednjih parametrih optimizacije: konstanta križanja  $Cr = 0,8$ ; utež  $F = 0,5$ ; strategija  $st. = 7$  (DE/rand/1/bin). Velikost populacije  $NP$  je bila nastavljena na vrednost  $5D$ , kjer  $D$  predstavlja dimenzijo problema. V konkretnem primeru je dimenzija optimizacijskega problema  $D = 10$ , saj je problem zahteval identifikacijo desetih parametrov.

Zaustavitveni kriterij optimizacijskega postopka je bil število dovoljenih iteracij, pri katerem algoritem ne najde boljše rešitve zadnje najboljše. V konkretnem primeru je bilo to število 50. Cilj optimizacije je bil identificirati termične parametre oz. doseči najboljše možno ujemanje med izmerjeno temperaturo na dejanski napravi in izračunano temperaturo s pomočjo MKE modela transformatorja.

Tabela 5.2: Termični parametri – mejne in identificirane/optimalne vrednosti

Fizikalna veličina	Parameter	Sp. meja	Zg. meja	Identificirana vrednost
Toplotna prevodnost silicijevega jekla - prirastek (1/°C)	$p_1$	-0,17	-0,08	-0,101
Toplotna prevodnost silicijevega jekla (W/m °C)	$p_2$	20	100	71,2
Spec. toplota za silicijevo jeklo - prirastek (1/°C)	$p_3$	1500	3000	2974,5
Specifična toplota za silicijevo jeklo (J/m <sup>3</sup> °C)	$p_4$	3e6	5e6	3,46e6
Toplotna prevodnost za baker - prirastek (1/°C)	$p_5$	-0,15	-0,05	-0,132
Toplotna prevodnost za baker (W/m °C)	$p_6$	200	400	271,6
Specifična toplota za baker - prirastek (1/°C)	$p_7$	1000	2000	1361
Specifična toplota za baker (J/m <sup>3</sup> °C)	$p_8$	1,5e6	4e6	2,90e6
Toplotna prevodnost zraka (W/m °C)	$p_9$	0,01	0,03	0,0226
Faktor konvekcije (W/m <sup>2</sup> °C)	$p_{10}$	5	20	6,41

Segrevanje transformatorja od vklopa v hladnem stanju in za čas osemurnega nazivnega obratovanja je bilo izmerjeno v določeni točki na navitju ( $P_1$ ) in na jedru ( $P_2$ ). Na osnovi rezultatov meritev in zapisane KF smo vključili optimizacijski algoritem DE v postopek identifikacije termičnih parametrov modela. Rezultati tranzientnega izračuna modela z vključenimi termičnimi parametri, ki so bili določeni v procesu identifikacije, kažejo na uspešnost metode. Posebej dobro ujemanje izračunov in meritev se kaže za točko  $P_1$  na sliki 5.15 a. Glede na vrednosti KF na koncu evolucije, in sicer  $q_{P_1} = 4,8 \times 10^{-3}$  in  $q_{P_2} = 26 \times 10^{-3}$ , je odstopanje med izračunano in izmerjeno temperaturo proporcionalno 0,48 % oz. 2,6 % površine pod pripadajočo izmerjeno krivuljo. To je razvidno tudi iz slike 5.15 b, kjer je RMS napaka oz. razlika relativno mala, in sicer 0,11 °C za točko  $P_1$  ter nekaj višja vrednost, približno 0,58 °C za točko  $P_2$ . Glede na rang, v katerem temperature opazujemo, lahko tudi ta rezultat označimo kot zelo dober.




Slika 5.15: a) Izmerjena in izračunana temp. (nazivna obremenitev) b) Absolutna napaka izračuna pri nazivni obremenitvi

Na sliki 5.15 b so podrobneje vidna odstopanja med izmerjenimi in izračunanimi vrednostmi. Prikazane so absolutne razlike, in sicer za vsak posamezni korak integracije. Iz slike prav tako vidimo, da je največje odstopanje v točki P<sub>2</sub>, in sicer v prvi tretjini opazovanega časovnega intervala integracije. V preostalem delu so razlike manjše oz. v rangu RMS napake.

Ujemanje izmerjene in izračunane temperature na sliki 5.15 a je bilo doseženo po vključitvi identificiranih termičnih parametrov v sam MKE model transformatorja. Ti parametri so bili dobljeni na koncu optimizacijskega procesa. Na začetku optimizacijskega procesa pa je bilo seveda ujemanje med izračunanimi in izmerjenimi temperaturami zelo slabo, saj na začetku evolucije običajno eksistirajo rešitve, ki so precej slabe. Slabe rešitve in s tem slaba ujemanja izračunov z meritvami so se pojavljala v začetnih generacijah, kar je na sliki 5.16 a prikazano z večjimi vrednostmi KF.

Algoritem DE skozi evolucijo išče boljše rešitve, in sicer na tak način, da hrani trenutno najboljšo rešitev v populaciji, dokler ne najde boljše. To lahko vidimo na sliki 5.16 a, ki prikazuje sledi KF  $q$ , in sicer tako za najboljši in najslabši osebek v vsaki posamezni generaciji. Na začetku evolucije, ko je populacija še raznolika, je razlika med vrednostjo KF najboljšega in najslabšega osebkov velika. Z večanjem števila generacij pa se vrednost  $q$  najboljšega osebkov vztrajno znižuje, kar pa velja tudi za vrednost  $q$  najslabšega osebkov. To je seveda posledica delovanja mehanizma selekcije DE algoritma. Generacije, v katerih je DE našel boljše rešitev kot zadnjo najboljšo, so označene z navzdol obrnjenimi trikotniki. Vrednosti v teh točkah so razlike v vrednosti  $q$  med najboljšim osebkom v opazovani generaciji in zadnjim najboljšim iz prejšnjih generacij. Seveda je možno, da algoritem DE v določeni generaciji ne najde boljše rešitve od predhodne, zato vse generacije tudi niso označene. Po približno 70-ih generacijah sta vrednosti KF  $q$  tako za najboljši kot tudi najslabši osebki v generaciji identični, kar pomeni, da je celotna populacija konvergirala k eni in isti rešitvi. Zaradi izbranega zaustavitvenega kriterija se je optimizacijski proces oz. evolucija nadaljevala naslednjih 50 generacij in je trajal približno 120 generacij. Ker ni bilo nobenih sprememb po 70-ti generaciji, so rezultati na sliki 5.16 prikazani do zaokrožene 100-te generacije.






Slika 5.16: a) Prikaz konvergence optimizacijskega postopka b) Trajektorije najboljšega osebk skozi celo evolucijo

Iskanje optimalne rešitve skozi celotno evolucijo je predstavljeno na sliki 5.16 b, kjer so vidne trajektorije parametrov, ki pripadajo najboljšemu osebk. Ker imajo parametri različne enote in so njihove vrednosti v različnih rangih, smo jih normirali na vrednosti med 0 in 1.

Za drugo oceno dobljene rešitve optimizacijskega problema smo primerjali rezultat modela z vključenimi identificiranimi parametri ter meritvami dejanske naprave pri spremenjenih okoliščinah. V ta namen smo spremenili obremenitev transformatorja z nazivne na 2/3 nazivne obremenitve. Rezultat primerjave meritev in izračunov za novo delovno točko transformatorja je prikazan na sliki 5.17. Slika prikazuje rast temperature v izbranih točkah navitja in jedra transformatorja, in sicer od hladnega stanja za čas 4-ih ur delovanja pri 2/3 nazivne obremenitve transformatorja.



Slika 5.17: Izračunana in izmerjena temperatura pri 2/3 nazivne obremenitve

Odstopanje med meritvijo in izračunom v točki P<sub>1</sub> je proporcionalno 3.4 % površine pod pripadajočo izmerjeno krivuljo, v točki P<sub>2</sub> pa je odstopanje proporcionalno 2.5 %. Skupna ocena ujemanja med izmerjenimi in izračunanimi krivuljami temperature je nekoliko slabša kot v prvem primeru. Glede na to, da govorimo o rezultatih, ki sodijo v domeno temperature, lahko tudi ta odstopanja ocenimo kot majhna oz. zadovoljiva.

## 5.3 Določitev parametrov modela plinskega odvodnika s pomočjo meritev in optimizacije

### 5.3.1 Uvod


V omrežju se lahko pričakovano ali nepričakovano vedno pojavijo napetosti, ki so višje od dovoljenih nazivnih napetosti oz. najvišjih dovoljenih napetosti opreme. Najbolj pogosti vplivi, ki lahko povišajo napetost v omrežju so razne stikalne manipulacije (vklopi in izklopi tokokrogov, obratovalne motnje, zemeljski stiki, izpad obremenitve, izklopi okvar, vklop neobremenjenega voda, ferorezonanca, itn.) ter atmosferske razelektritve [107].

Današnje elektronske naprave, kot so računalniki, telefoni, hi-fi komponente, itn., so bolj občutljive na prenapetosti in različne prehodne pojave kot kadarkoli prej [108]. Zaradi tega jih je pred prenapetostmi oz. njihovimi škodljivimi vplivi potrebno ščititi. Ustrezno zaščito predstavljajo zaščitni sklopi s prenapetostnimi odvodniki, ki prenapetosti po najkrajši možni poti odvedejo v zemljo. Primer najpreprostejšega in najstarejšega prenapetostnega odvodnika je zaščitno iskriilo [2].

### 5.3.2 Predstavitev objekta

Prednost plinskih odvodnikov (PO) pred drugimi vrstami odvodnikov je v njihovi mali prostornini, še večja prednost pa je ognjevarnost, saj ostajata plazma in oblok, ki sta posledica delovanja odvodnika, zaprta v celici [109].

Obravnavani PO je sestavljen iz valjastega in hermetično zaprtega telesa. Telo odvodnika, ki je z keramike, stekla ali drugega izolacijskega materiala, zapirata dve kovinski elektrodi (slika 5.18 a). V njegovi notranjosti se nahaja žlahtni plin (ali mešanica – običajno se uporabljajo neon, argon, helij, vodik in dušik), in sicer pod določenim tlakom, po navadi manjšim od atmosferskega.



Slika 5.18: a) Zgradba PO b) Fotografija vzorca c) Notranjost odsluženega PO

Na sliki 5.18 a je s številko 1 označena elektroda. Številka 2 označuje izolacijski valj oz. telo odvodnika, številka 3 zračno režo napolnjeno z žlahtnim plinom, številka 4 pa prikazuje priključka elektrod. Na sliki 5.18 b vidimo, da je zgradba PO popolnoma osnosimetrična, na sliki 5.18 c pa je prikazana notranjost odsluženega PO, ki je že večkrat pogasil oblok v svoji notranjosti.

PO deluje tako, da ko napetost na odvodniku naraste nad določeno t. i. preskočno napetost, iskrišče preide iz neprevodnega v prevodno stanje. Ko je v prevodnem stanju, je padec napetosti na njem približno konstanten in neodvisen od toka. V tem stanju je napetost obloka med 10 in 30 V, vrednost pa je odvisna predvsem od vrste plina ali mešanice, s katero je odvodnik napolnjen [107].

### 5.3.3 Predstavitev matematičnega modela

Model PO mora opisovati dinamični proces vžiga odvodnika kot tudi proces delovanja električnega obloka v njem in prekinitve električnega toka. Izveden je kot spremenljiva upornost v "črni škatli", krmilimo pa jo s posameznimi podbloki, kateri vsak zase predstavlja eno od fizikalni dogajanj v PO [107]. Model z vsemi fizikalnimi fazami delovanja je podrobneje predstavljen v 4. poglavju.

Prednost uporabljenega matematičnega "Black box" modela PO je predvsem ta, da zanj ni potrebno poznavanje parametrov fizikalnih procesov, kot so temperatura  $T$ , tlak plina  $p$ , entalpija  $h$ , gostota plina  $\rho$ , volumen  $V$  in masa  $m$ , kjer je nekatere težko ali včasih celo nemogoče izmeriti. Nasprotno pa je slabost obravnavanega modela večinoma nenatančnost rezultatov oz. odzivov modela, saj je zajetih premalo parametrov, ki so soudeleženi pri procesu delovanja odvodnika [107].

Učinkovit način za načrtovanje zaščitnih naprav je simulacija njihovega delovanja. Za izvajanje natančnih in ustreznih računalniških simulacij je pomembno, da se obnašanje modelov ujema z dejansko napravo, v ta namen pa je potrebno natančno določiti njihove parametre. Na področju odvodnikov prenapetosti so za določitev parametrov modela predlagane različne rešitve [110] – [114], ki temeljijo predvsem na matematičnem razmerju med parametri modela in izmerjenimi odzivi na dejanski napravi. Avtorji v [110] predlagajo "trial and error" iterativni postopek, kjer izvajajo popravke posameznih parametrov dokler ne najdejo zadovoljivih vrednosti. Pri tem je potrebno omeniti, da so začetne vrednosti parametrov predhodno določene na podlagi predlaganih obrazcev. Po drugi strani pa avtorji v [111] predlagajo metodo, ki ne zahteva iterativnih popravkov, saj metoda temelji na direktnem izračunu vrednosti. V [112] in [113] sta predlagana in uporabljena iterativna postopka, ki temeljita na determinističnih optimizacijskih postopkih, vendar so vse do sedaj omenjene metode primerne za metal-oksidne varistorje. Zaradi razlik metal-oksidnega varistorja in PO, kot

tudi zaradi kompleksnosti uporabljenega modela PO, so ti postopki zanj neuporabni. Avtorji v [114] pa obravnavajo model PO, pri katerem so določali parametre po iterativnem postopku, kjer so v vsakem koraku spreminjali en element. Proces določitve parametrov je tako časovno zelo zahteven, kar je posledica velikega števila parametrov, ki jih je potrebno določiti in posledično velikega prostora rešitev. Predstavljeni iterativni postopek za primer kompleksnejših modelov ni neprimeren.

### 5.3.4 Kriterijska funkcija

Ustrezne odzive matematičnega modela izbrane naprave dobimo tako, da na realnem objektu izmerimo časovne odzive, na osnovi katerih določimo parametre modela tako, da iz simulacij dobimo časovni odziv, ki se naj čim boljše ujema s časovnim odzivom iz meritev. Na rezultate simulacije pa običajno vpliva večje število parametrov modela, kjer med nekaterimi vlada tudi direktna soodvisnost. Posledično je skoraj nemogoče ali pa je časovno zelo zahtevno ročno nastavljanje teh parametrov v smislu doseganja čim boljšega ujemanja odzivov modela z rezultati meritev. V ta namen je tako smiselno uporabiti optimizacijski algoritem za določitev parametrov modela PO, s katerimi dosežemo minimalno odstopanje med simuliranimi in izmerjenimi odzivi.


Odstopanje signalov meritev in simulacij lahko tudi v tem primeru matematično ovrednotimo z normami. Za uporabo norm v smislu KF pri optimizaciji modela PO je najprej potrebno v vsaki diskretni točki izračunati razliko med izmerjenim in simuliranim signalom tj. vektor napak za napetost  $e_u$  in tok  $e_i$ :

$$\mathbf{e}_u = \mathbf{u}_{\text{mer}} - \mathbf{u}_{\text{sim}} \left[ n \times 1 \right], \quad \mathbf{e}_i = \mathbf{i}_{\text{mer}} - \mathbf{i}_{\text{sim}} \left[ n \times 1 \right] \quad (5.9)$$

kjer sta  $\mathbf{u}_{\text{mer}}$  in  $\mathbf{u}_{\text{sim}}$  napetosti,  $\mathbf{i}_{\text{mer}}$  in  $\mathbf{i}_{\text{sim}}$  toka ter  $n$  velikost vektorja oz. število odtipkov. Ti vektorji predstavljajo osnovo za izračun Evklidske norme [115], priprava KF pa je analogna tisti, ki je predstavljena v podpoglavju 5.2.


### 5.3.5 Meritve

Meritve vzorcev PO so bile opravljene v Infrastrukturnem centru za elektroenergetske meritve ICEM-TC, katerega sestavni del je Laboratorij za močnostna preskušanja. Preskušanelec je bil v času preskušanja vključen v električno vezje, kot je prikazano na sliki 5.19. Delovanje PO pri omrežni napetosti smo realizirali z vključitvijo prenapetostnega vala. To smo dosegli s pomočjo Schafnerjevega generatorja, katerega prenapetostni val standardne oblike 1,2/50  $\mu\text{s}$  smo superponirali v omrežno napetost sinusne oblike.



Slika 5.19: Model PO vključen v merilno progo

S pomočjo osciloskopa in ustreznih merilnih pretvornikov smo merili smo padec napetosti na vzorcu in tok skozi njega (slika 5.20). Tipanje osciloskopa je bilo nastavljeno na "visoko ločljivost", s čimer smo v časovnem intervalu 100 ms zajemali po 1.000.000 merilnih vrednosti.




Slika 5.20: Signal napetosti in toka izmerjen pri delovanju PO

Meritve odzivov PO so narejene na več vzorcih istega proizvajalca. Pri tem je en vzorec prožen večkrat zaporedoma. V štirih delovanjih je le-ta uspel odvesti prenapetostni val v zemljo ter ugasniti oblok, pri petem poskusu pa je že odpovedal. V tem primeru je tokokrog prekinila predvarovalka, ki je bila vključena v merilno progo.

### 5.3.6 Primerjava rezultatov meritev in simulacij

Na slikah 5.21 a in 5.21 b so prikazani rezultati meritev odzivov PO ter rezultati simulacije njegovega modela. Kot vidimo je oblika signalov sorodna, vendar pa izstopa tako amplitudna kot tudi časovna neusklajenost. Za boljše ujemanje je potrebno nastaviti parametre modela. Pri tem parametre, kot so napajalna napetost  $U_p$  na vhodu modela PO in trenutek proženja  $t_{pr}$  določimo iz podatkov o meritvi.




Slika 5.21: Primerjava izmerjenih in izračunanih a) napetosti in b) tokov

Pred optimizacijo modela oz. identifikacijo njegovih parametrov smo najprej poiskali tiste parametre, ki imajo pomemben vpliv na odziv modela PO. Ti parametri so  $R_{\text{dov}}$ , ki jo sestavljata upornost PO in upornost dovoda, induktivnost  $L_{\text{dov}}$ , *Toeplerjeva* konstanta  $k_T$ , časovna konstanta obloka  $\tau$ , napetost obloka  $U_{\text{arc}}$ , izgube obloka  $P_0$  ter končna upornost razelektritve  $R_{\text{ki}}$ .

Ročno nastavljanje parametrov v smislu doseganja najboljšega možnega ujemanja merjenih in simuliranih signalov je praktično nemogoče že zaradi velikega števila le-teh, predvsem pa zaradi njihove medsebojne odvisnosti. Eden od načinov za identifikacijo optimalnih parametrov modela je uporaba optimizacijskega algoritma, ki je sposoben obvladovati velike prostore rešitev in pri tem poiskati globalno gledano najboljšo možno rešitev. V našem primeru smo v ta namen uporabili večkrat dobro izkazano DE in jo vključili v algoritem, prikazan na sliki 5.22.

Na sliki 5.18 c je moč opaziti fizikalne spremembe v notranjosti odvodnika (oblika elektrod), ki so posledica termične obdelave z oblokom, ki se pojavi pri vsakem delovanju odvodnika. Tem vplivom je seveda izpostavljen tudi sam plin v odvodniku, katerega karakteristike se prav tako spreminjajo skupaj s številom delovanj PO. To pomeni, da bodo fizikalne spremembe imele vpliv na delovanje dejanske naprave, katerim mora slediti tudi model. Zato je potrebno tudi izvesti večkratno optimizacija modela PO na rezultate meritev posameznega delovanja merjenca. Nadgradnja univerzalnega algoritma za načrtovanje in identifikacijo parametrov v orodje za parametrično analizo omogoča nakazovanje tendence spreminjanja parametrov v primeru, če so le-ti odvisni od zunanjih vplivov na objekt, kot to velja za primer delovanja PO prenapetosti. Postopek zahteva koračno izvajanje identifikacije parametrov modela, in sicer individualno izvajanje za vsako posamezno meritev oz. spremembo stanja objekta, ki ima za posledico nereverzibilno spremembo njegove zgradbe oz. njegovih lastnosti. Iz pridobljenih optimalnih parametrov modela za vsako individualno meritev lahko z regresijo napovemo vrednosti parametrov za kasnejša, še neizvedena delovanja/stanja naprave. Drugače zapisano nam algoritem omogoča oceno sprememb parametrov modela zaradi zunanjih vplivov na dejanski napravi, ki se

odražajo na njenih odzivih in se posredno preko merilnih rezultatov prenašajo na raven matematičnega modela naprave.



Slika 5.22: Algoritem za identifikacijo parametrov in parametrično analizo

### 5.3.7 Rezultati optimizacije

Parametri modela PO, katere je algoritem spreminjal z namenom identifikacije njihove vrednosti v kontekstu najboljšega možnega ujemanja med odzivi modela in realne naprave, so bili predstavljeni v prejšnjem podpoglavju. Meje optimizacijskih parametrov oz. prostor preiskovanja pa je predstavljen v tabeli 5.3.

Optimizacijo modela PO smo izvedli za serijo meritev na vzorcu PO, katerega smo poimenovali "vzorec št. 1". Zaporedne meritve so izvajane na način, da se je po vsakem delovanju vzorec ohladil, preden smo preskus ponovili. Meritve so bile opravljene tudi na drugih dveh vzorcih PO iz iste serije, poimenovali pa smo jih "vzorec št. 2" in "vzorec št. 3". V nadaljevanju so najprej prikazani rezultati za vzorec št. 1 [116].


## Rezultati optimizacije za meritev št. 2, PO vzorec št. 1

Rezultat optimizacije so optimalne vrednosti optimizacijskih parametrov, s katerimi dosežemo najboljše ujemanje napetostnega in tokovnega signala iz modela PO s signali, katere smo dobili iz meritev na realnem objektu. Za primer meritve št. 2 na vzorcu št. 1 so v tabeli 5.3 prikazane iskane vrednosti.

Tabela 5.3: Meje optimizacijskih parametrov in optimalne vrednosti

	$R_{dov}$ [ $\Omega$ ]	$L_{dov}$ [mH]	$k$ [Vs/m]	$\tau$ [s]	$U_{arc}$ [V]	$P_0$ [W]	$R_{ki}$ [ $\Omega$ ]
Sp. meja:	0,1	1e-5	0,001	0,15e-6	5	0	0,001
Zg. meja:	0,3	35e-5	0,050	5e-6	20	200	0,040
Optimum:	0,2448	0,2248e-3	0,02168	0,4365e-6	12,69	12,63	0,0105

Na slikah 5.23 a in 5.23 b so izrisane trajektorije vseh sedmih optimizacijskih parametrov, in sicer za najboljši kot tudi najslabši osebek. Ker so enote optimizacijskih parametrov različne, smo jih s pomočjo v tabeli 5.3 definiranih mej tudi normirali na vrednosti med 0 in 1.




Slika 5.23: Vzorec št. 1, meritev št. 2 – a) trajektorije parametrov najboljšega in b) najslabšega osebk, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji

Konvergenca postopka je razvidna iz slik 5.23 c in 5.23 d, kjer se vidi, da se algoritem relativno hitro približa optimumu, vendar se približevanje nadaljuje še dobrih 300 generacij, v katerih algoritem nadaljuje pot proti optimumu z zelo majhnimi koraki, ki so na grafu praktično neopazni. Spremembe so opazne šele na sliki 5.24, kjer so izrisane




razlike v vrednostih KF med najboljšim osebkom v opazovani generaciji in njegovim predhodnikom.



Slika 5.24: Sprememba vrednosti KF skozi evolucijo za najboljši osebek

Z obravnavanim modelom PO in vključenimi optimalnimi parametri iz tabele 5.3, dosežemo odlično ujemanje oz. pokrivanje simuliranih signalov napetosti in toka z izmerjenimi signali na vzorcu PO št. 1 pri meritvi št. 2.

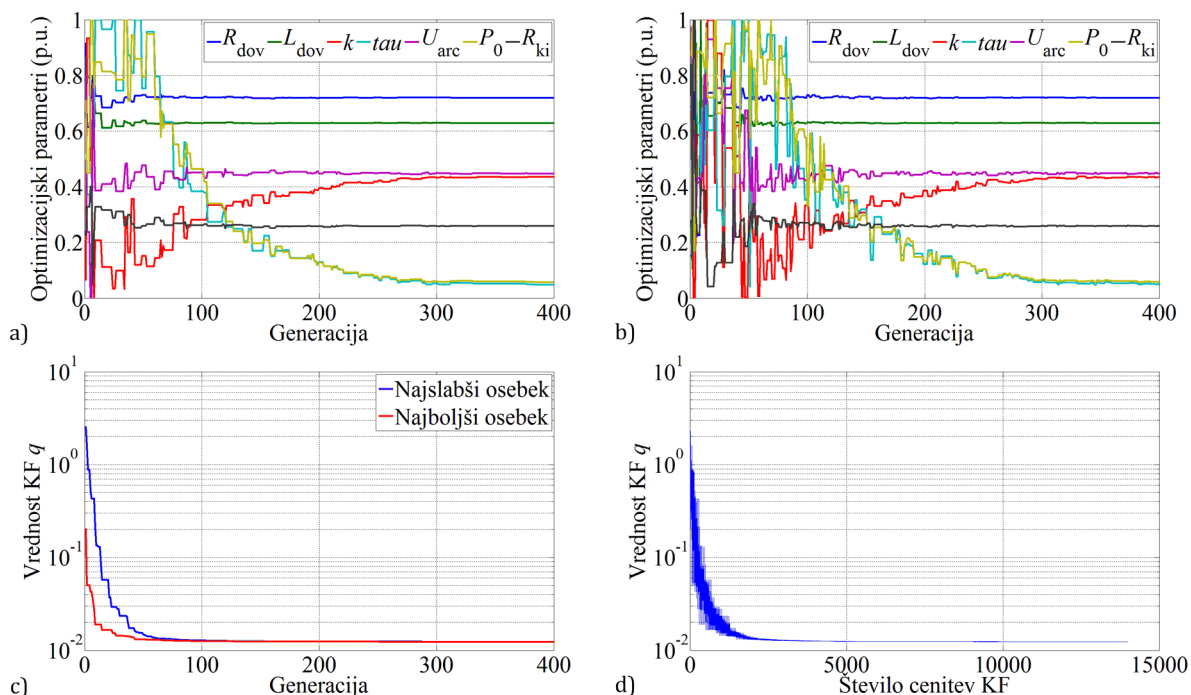
Grafični prikaz izmerjenih in simuliranih vrednosti je predstavljen na sliki 5.25, kjer sta modri konici posledica uporabe Schafnerjevega generatorja za proženje odvodnika. Pri grafu napetosti je vidna konica dejanskega napetostnega signala, medtem ko pri signalu toka prikazana konica predstavlja motnjo, ki se je pojavila pri meritvi oz. zajemu signalov.




Slika 5.25: Izmerjeni in s pomočjo optimalnih parametrov izračunani signali za a) napetost in b) tok

Model PO lahko potrdimo v primeru, ko je ugotovljeno zadostno ujemanje rezultatov simulacij in meritev. V nadaljevanju so predstavljeni rezultati še za ostale tri meritve na vzorcu št. 1.


### Rezultati optimizacije za meritev št. 1, 3 in 4 - PO vzorec št. 1



Slika 5.26: Vzorec št. 1, meritev št. 1 – a) trajektorije parametrov najboljšega in b) najslabšega osebk, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji



Slika 5.27: Vzorec št. 1, meritev št. 3 – a) trajektorije parametrov najboljšega in b) najslabšega osebk, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji




Slika 5.28: Vzorec št. 1, meritev št. 4 – a) trajektorije parametrov najboljšega in b) najslabšega osebka, c) vrednosti njune KF ter d) vrednosti KF v vsaki iteraciji

Z vsakim delovanjem PO oblok vpliva na njegove fizikalne in električne lastnosti, vendar se postavlja vprašanje v kolikšni meri. Iz serije narejenih meritev smo za vsako posebej optimirali parametre modela PO (slika 5.22) tako, da so se njegovi odzivi čim bolj pokrivali s posameznimi rezultati pripadajočih meritev. Primerjava vrednosti identificiranih optimizacijskih parametrov (tabela 5.4) nam lahko sedaj pokaže tendenco spreminjanja parametrov (slika 5.29) v odvisnosti od števila delovanj PO. Pred izvedbo postopka smo pričakovali, da bodo optimizacijski parametri pri medsebojni primerjavi jasno nakazali smer oz. tendenco sprememb v odvisnosti od števila delovanj PO. Iz dobljenih rezultatov na sliki 5.29 lahko zaključimo, da tendenco naraščanja kažejo le nekateri parametri, pri drugih pa ne moremo z gotovostjo trditi, kakšna je njihova tendenca spreminjanja že zaradi malega števila meritev. V danih okoliščinah pa je glavni razlog, da nekateri parametri ne kažejo jasne tendence, napaka meritev, in sicer tako naključna kot tudi sistematična, saj je velikost napake ravno v rangu velikosti sprememb, ki jih določeni parametri povzročajo.

Tabla 5.4: Optimalne vrednosti parametrov določenih za vzorec PO št. 1

	$R_{dov}$ [ $\Omega$ ]	$L_{dov}$ [mH]	$k$ [Vs/m]	$\tau$ [s]	$U_{arc}$ [V]	$P_0$ [W]	$R_{ki}$ [ $\Omega$ ]
meritev 1	0,2439	0,2239e-3	0,02238	0,3885e-6	11,72	11,53	0,0111
meritev 2	0,2448	0,2248e-3	0,02168	0,4365e-6	12,69	12,63	0,0105
meritev 3	0,2477	0,2241e-3	0,02288	0,4306e-6	11,50	12,31	0,0114
meritev 4	0,2463	0,2245e-3	0,02245	0,5485e-6	12,11	15,72	0,0115
povprečje	0,2454	0,2245e-3	0,02235	0,4511e-6	12,01	13,05	0,0112



Slika 5.29: Spremembe parametrov modela v odvisnosti od števila delovanj vzorca št. 1

Iz serije rezultatov smo v naslednjem koraku izračunali povprečne vrednosti (tabela 5.4), ki so na sliki 5.29 označene z rdečo linijo. Odzive modela s temi parametri smo primerjali še z rezultati meritev na vzorcih št. 2 in št. 3, in sicer vzorcih istega proizvajalca, istega modela in iz iste serije. Oceno ujemanja meritev in simulacij podajajo vrednosti KF v tabeli 5.5 (vrednosti pomnožene s 100 predstavljajo napako v odstotkih).

Tabla 5.5: Ocena ujemanja izmerjenih in izračunanih signalov (vrednost KF)

	Meritev št. 1	Meritev št. 2	Meritev št. 3	Meritev št. 4
Vzorec št. 1	0,01239	0,01368	0,01488	0,01807
Vzorec št. 2	0,01395	/	/	/
Vzorec št. 3	0,02027	/	/	/

Manjša kot je vrednost KF, manjša je odstopanje med izračunanimi in izmerjenimi signali. Za primer vzorca št. 2 vidimo, da je ujemanje zelo dobro, in sicer približno enako dobro kot v primerih, izračunanih za vzorec PO št. 1. Pri vzorcu št. 3 smo sicer dobili največje odstopanje signalov, vendar je to še vedno dovolj dobro, saj je v rangi odstopanja, ki smo ga dobili pri vzorcu št. 1 za meritev št. 4.

Glede na prikazane rezultate, lahko ugotovimo, da so povprečne vrednosti optimizacijskih parametrov, določene na osnovi vzorca št. 1, povsem uporabne in korektne za druga dva vzorca PO in s tem tudi za ostale vzorce iz iste serije.

## 5.4 Večkriterijsko optimiranje konfiguracije omrežja v povezavi s stroški in zanesljivostjo

### 5.4.1 Uvod

Stroški gradnje in zanesljivost delovanja SN omrežja je odvisna od mnogih faktorjev, med drugim pomembneje od stopnje vzankanja in stopnje pokablitve trase. Navadno je del SN omrežja sestavljen bodisi iz kabla bodisi iz nadzemnega voda, splošno znano pa je, da je na kablovodih manj okvar in je posledično zanesljivost takšnega voda večja. Po drugi strani je sanacija morebitnih okvar kablovoda v primerjavi z nadzemnim vodom veliko dražja, saj je okvaro težje locirati, prav tako pa je na mestu okvare potrebno kabel izkopati, kar je povezano z zemeljskimi deli. Nasprotno je pri nadzemnem vodu napako lažje locirati, saj jo lahko odkrijemo že vizualno, prav tako pa je lažje pristopiti k njeni sanaciji. Tudi investicijski strošek kablovoda je nekajkrat višji v primerjavi z nadzemnim vodom, saj je okvirna cena kabla 4.000 €/km, medtem ko je cena nadzemnega voda približno 1.300 €/km.

Z vzankanjem lahko povečamo zanesljivost napajanja nekega odjemalca, vendar se z večanjem stopnje vzankanja povečuje skupna dolžina voda, s tem pa se povečuje tudi verjetnost za nastanek okvare, ki raste skupaj z dolžino voda. Prav tako daljši vod predstavlja večji investicijski strošek.

Na skupne stroške vpliva tudi čas odpravljanja okvare. Večje število delavcev, ki odpravlja okvaro, pomeni nižji strošek v smislu manjših odškodnin zaradi nedobavljene energije, posledično pa številčnejše ekipe predstavljajo višji operativni strošek.

Iz zapsanega je moč sklepati, da za katerokoli izbiro se opredelimo, po eni strani pridobimo, po drugi pa izgubimo. Z ustrezno izbiro konfiguracije omrežja tako lahko prihranimo pri investicijah, in sicer na račun znižanja zanesljivosti delovanja omrežja, hkrati pa lahko ta izbira pomeni dodatne stroške za sanacijo pogostejših okvar in višje odškodnine zaradi nedobavljene energije.

### 5.4.2 Predstavitev kriterijskih funkcij

Opisani problem je zelo težko reševati brez pravilnega pristopa. Eden od pristopov je uporaba optimizacijskega algoritma. V ta namen je potrebno definirati ustrezne KF oz. kriterije, s katerimi lahko ocenjujemo in med seboj primerjamo različne rešitve. Ko v naprej poznamo prioriteto posameznih kriterijev, optimizacijske probleme običajno rešujemo tako, da vse kriterije združimo v en sam kriterij, in sicer z metodo utežnih vsot [26]. Rezultat takšnega pristopa je ena sama optimalna rešitev.

Če preferenc ne poznamo in želimo poiskati množico enakovrednih rešitev, potem lahko uporabimo algoritem za večkriterijsko optimizacijo DEMO. Na osnovi množice teh rešitev lahko uporabnik poljubno spreminja prioriteto opazovanim kriterijem. Pri tem, ko uporabnik izvede izbiro, ki z določeno mero zadovoljuje opazovani kriterij, ta izbira hkrati pomeni tudi najboljšo možno zadovoljitev drugih kriterijev. Kriterija optimizacije sta v konkretnem primeru strošek in zanesljivost omrežja (v nadaljevanju kakovost), parametri optimizacije pa so stopnja pokablitve, stopnja vzankanja in čas popravila (velikost ekip za sanacijo okvar). Običajno strošek in kakovost predstavljata konfliktna kriterija, tako da znižanje stroškov oz. izboljševanje po tem kriteriju pomeni poslabševanje po kriteriju kakovosti in obratno. Pri tem strmimo k rešitvi, s katero lahko dosežemo čim višjo obratovalno zanesljivost omrežja ob minimalnih investicijskih in obratovalnih stroških. Drugače povedano je cilj v konkretnem primeru poiskati tisto konfiguracijo omrežja, ki bo pri stroških, katere smo pripravljene kriti, nudila najvišjo kakovost. Pri tem sta kriterija strošek in kakovost sestavljena iz množice komponent, kot je prikazano v nadaljevanju.

### **Kriterijska funkcija stroškov $C$**

Splošna rešitev optimizacijskega problema je vektor  $\mathbf{x}_i$ , ki vsebuje naslednje parametre:

$$\mathbf{x}_i = [r_{vz}, r_{kb}, t_r] \quad (5.10)$$

kjer je  $r_{kb}$  stopnja pokablitve oz. razmerje med dolžino podzemnih in dolžino vseh vodov,  $r_{vz}$  stopnja vzankanja oz. razmerje med dolžino vzankanih in dolžino vseh vodov ter  $t_r$  čas popravila oz. sanacije okvare. Skupni stroški  $C$  (slika 5.34 a) so sestavljeni iz več komponent, in sicer:

$$C(\mathbf{x}_i) = S(\mathbf{x}_i) + V(\mathbf{x}_i) + S_v(\mathbf{x}_i) \quad (5.11)$$

kjer so  $S$  stroški zaradi prekinitev in trajanja prekinitev,  $V$  investicije oz. stroški za zagotavljanje kakovosti ter  $S_v$  stroški vzdrževanja. Stroški zaradi prekinitev in trajanja prekinitev  $S$  so vsota dveh komponent, in sicer stroškov nenačrtovanih  $S_{Ne}$  in stroškov načrtovanih prekinitev  $S_{Na}$ :

$$S(\mathbf{x}_i) = S_{Ne}(\mathbf{x}_i) + S_{Na}(\mathbf{x}_i) \quad (5.12)$$

Investicijski stroški  $V$  za zagotavljanje kakovosti so sestavljeni iz cene nadzemnega voda  $V_{dv}$  ter cena kablovoda  $V_{kv}$ :


$$V(\mathbf{x}_i) = V_{dv}(\mathbf{x}_i) + V_{kv}(\mathbf{x}_i) \quad (5.13)$$

Stroški vzdrževanja  $S_v$  so definirani kot:

$$S_v(\mathbf{x}_i) = S_{dv}(\mathbf{x}_i) + S_{kb}(\mathbf{x}_i) \quad (5.14)$$


kjer sta  $S_{dv}$  in  $S_{kb}$  strošek za vzdrževanje nadzemnega voda oz. kablovoda. Vse komponente stroškov so v nadaljevanju predstavljene tudi grafično, in sicer kot funkcija stopnje pokablitve, stopnje vzankanja ter časa popravila. Vhodni podatki za izračune so pridobljeni s pomočjo računalniškega programa GREDOS v sodelovanju z avtorjem [117], in sicer konkretno za del SN omrežja na Primorskem.

Na sliki 5.30 a so predstavljeni stroški načrtovanega izpada, ki so odvisni samo od stopnje pokablitve in stopnje vzankanja, medtem ko čas popravila na njih nima vpliva. Razlog za to je v tem, da ta komponenta ne zajema stroškov za sanacijo okvare, saj gre za vnaprej planirane prekinitve (npr. redno vzdrževanje). Slika 5.30 b prikazuje stroške nenačrtovanega izpada (okvare), in sicer za označeni čas trajanja sanacije okvare.



Slika 5.30: Stroški zaradi a) načrtovanih in b) nenačrtovanih prekinitev in trajanja prekinitev v odvisnosti od stopnje vzankanja in pokablitve ter časa popravila


Na sliki 5.31 so podobno kot na sliki 5.30 prikazane preostale komponente stroškov  $C$ , in sicer so na sliki a prikazani stroški vzdrževanja in na sliki b stroški investicij. Stroški vzdrževanja so sicer prikazani samo za izbrani čas popravila  $t_r$ , ki pa imajo bistven vpliv na to komponento. Nasprotno, stroški investicij nimajo povezave s stroški popravil, vidimo pa lahko, da so močno odvisni od izbire konfiguracije omrežja, kot tudi to, da imajo investicije prevladujoč vpliv na skupne stroške  $C$ .



Slika 5.31: a) Stroški vzdrževanja b) Investicijska vlaganja


### Kriterijska funkcija kakovosti $Q$

Kriterij kakovosti smo določili na osnovi sistemskih kazalcev  $SAIFI$  in  $SAIDI$ , ker je  $SAIFI$  indeks povprečne frekvence prekinitev v sistemu in  $SAIDI$  indeks povprečnega trajanja prekinitev napajanja v sistemu [118], in sicer v minutah ali urah. Glede na vzrok lahko prekinitev ločimo na načrtovane (vzdrževanje) in nenačrtovane (okvare). Na sliki 5.32 so prikazani grafi funkcij kazalcev  $SAIFI$  in  $SAIDI$  za primer nenačrtovanih izpadov. Ker je kazalec  $SAIDI$  odvisen tudi od časa popravila okvare, je za njega izrisan graf, ki velja za označeni čas popravila. Vidimo, da ima v obeh primerih stopnja pokabljenosti bistven vpliv na zanesljivost obratovanja omrežja.



Slika 5.32: Sistemska kazalca za nenačrtovane prekinitev v odvisnosti od stopnje vzkanjanja in pokabljenosti ter časa popravila - a)  $SAIFI$  in b)  $SAIDI$

Pri načrtovanih prekinitev časi popravil nimajo vpliva na sistemska kazalca, katerih grafe prikazuje slika 5.33. V tem primeru je vpliv stopnje vzkanjanja izrazitejši kot v prejšnjem primeru. Višja stopnja vzkanjanja tukaj pomeni več prekinitev in trajanja prekinitev, kar znižuje kakovost oz. zanesljivost obratovanja. Razlog za takšne rezultate v prikazanem primeru je ta, da se z višanjem stopnje vzkanjanja, povečuje tudi skupna dolžina vodov, kar pomeni večje število načrtovanih posegov v omrežje.



Slika 5.33: Sistemska kazalca za načrtovane prekinitev v odvisnosti od stopnje vzkanjanja in pokabljenosti - a)  $SAIFI$  in b)  $SAIDI$

V nadaljevanju sta prikazani funkcija kakovosti  $Q(\mathbf{x}_i)$  ter funkcija skupnih stroškov  $C(\mathbf{x}_i)$ .




Ker so vse komponente stroškov izražene v isti enoti (€), dobimo skupno funkcijo stroškov tako, da posamezne komponente preprosto seštejemo. V primeru kakovosti pa imajo posamezne komponente različne enote. Ker želimo, da so prispevki vseh komponent enakovredni, smo njihove vrednosti normirali in skupno funkcijo kakovosti izračunali po naslednjem obrazcu:

$$Q = 1 - \frac{\sqrt{\left(\frac{SAIFI_{Ne} + SAIFI_{Na}}{SAIFI_{Ne\max} + SAIFI_{Na\max}}\right)^2 + \left(\frac{SAIDI_{Ne} + SAIDI_{Na}}{SAIDI_{Ne\max} + SAIDI_{Na\max}}\right)^2}}{\sqrt{2}} \quad [\text{p.u.}] \quad (5.15)$$

kjer sta oznaki "Ne" in "Na" vezani na nenačrtovane oz. načrtovane prekinitve napajanja odjemalcev. Dodatek "max" predstavlja vrednosti, ki so veljavne za primer najmanj ugodne konfiguracije omrežja z vidika zanesljivosti njegovega delovanja. Spodnja mejna zanesljivosti je povezana s predpisanim vzdrževanjem in zagotavlja osnovne pogoje varnega obratovanja.

V splošnem težimo k čim nižjim stroškom in čim višji kakovosti, vendar iz grafov KF na sliki 5.34 vidimo, da sta si podana kriterija konfliktna. Namreč, če rešitev izboljšujemo po kriteriju stroškov (boljša cena), ima to za posledico poslabšanje po kriteriju kakovosti (slabša kakovost). Zato je cilj optimizacije problema poiskati množico enakovrednih rešitev, pri katerih zadovoljimo vse kriterije, kolikor je mogoče.

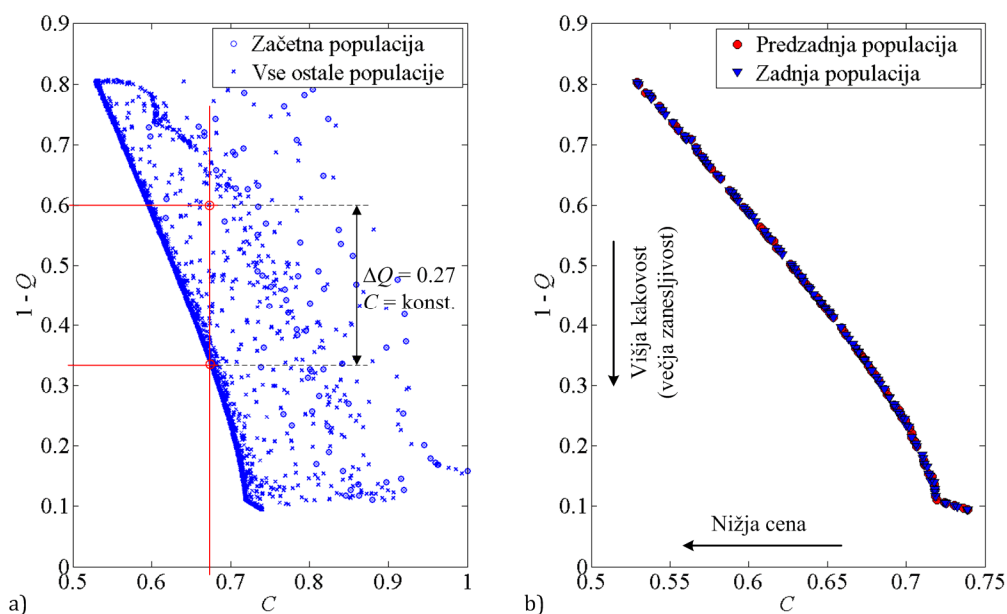


Slika 5.34: Kriterijski funkciji – a) skupni stroški  $C$  ter b) kakovost  $Q$  v odvisnosti od stopnje vzkanja, stopnje pokablitve in časa popravila

### 5.4.3 Rezultati optimizacije

Kriterijski funkciji, ki sta prikazani na sliki 5.34, služita za ocenjevanje rešitev optimizacijskega algoritma ter za tvorjenje prostora kriterijev. Prostor spremenljivk tvorijo tri spremenljivke, prostor dovoljenih rešitev pa je omejen z  $r_{vz} = [0,50;1]$ ,  $r_{kb} = [0,21;1]$  ter  $t_r = [12;48]$ . Rezultati uporabe algoritma DEMO z izbrano velikostjo populacije  $NP = 100$  so prikazani na sliki 5.35, kjer imamo na sliki a prikazane vse

poskuse algoritma za določitev Pareto optimalne fronte, na sliki b pa množico enakovrednih rešitev na tej fronti.



Slika 5.35: Rezultat optimizacije z uporabo DEMO algoritma – a) prikaz vseh rešitev v prostoru kriterijev dobljenih skozi celotno evolucijo in b) prikaz zadnje ter predzadnje populacije (Pareto fronta)

Če izberemo boljšo rešitev po kriteriju stroškov, vidimo, da poslabšamo kakovost oz. zanesljivost sistema in obratno. Dejstvo pa je, če pogledamo rešitve na sliki 5.35 a pri kriteriju cene  $C$  (vrednost npr. 0,67), da imamo več rešitev, ki enako zadovoljujejo ta kriterij, vendar so te rešitve neenakovredne po kriteriju kakovosti  $Q$ . Na Pareto fronti tako leži rešitev, ki pri izbrani zadovoljitvi kriterija stroškov, v najboljši meri zadovoljuje kriterij kakovosti z vrednostjo 0,33 ( $1-Q$ : od tod sledi, da nižja vrednosti pomeni višjo kakovost); druga rešitev, ki leži navpično višje zgoraj pa pri vrednosti 0,6. Tukaj je tako viden pomen iskanja Pareto optimalne fronte, katerega smisel je najti konfiguracijo omrežja, ki bo nudila najvišjo možno zanesljivost delovanja omrežja, pri stroških ki smo jih pripravljene kriti oz. investirati. Če smo pripravljene iznos stroškov tudi povišati, lahko hitro ugotovimo, kaj to povišanje pomeni v kontekstu zanesljivosti in sicer tako, da novo rešitev preprosto odčitamo s Pareto fronte. Rezultati predstavljeni na sliki 5.34 b, torej rešitve s Pareto fronte, so podani tudi v tabelarični obliki v prilogi na strani 143.

## 5.5 Optimizacija skoznjika z uporabo algoritmov DE in KADE

### 5.5.1 Predstavitev problema

Skoznjik (slika 5.36) je element stikalnih naprav, katerega uporabljamo za prehod vodnikov in zbiralk, ki so na določenem električnem potencialu, skozi ozemljene kovinske stene in pregrade. Le-ta je v osnovi sestavljen iz izolacijskega telesa, ki je običajno iz epoksidne smole in v notranjosti obdan s kovinskim plaščem [2].



Slika 5.36: Fotografija različnih vrst skoznjikov


Eden najpomembnejših kriterijev pri načrtovanju skoznjikov je pravilno dimenzioniranje glede na električne prebojne trdnosti [3]. Vrednosti električnih poljskih jakosti v opazovanem področju skoznjika z okolico morajo biti nižje od dovoljenih vrednosti za posamezno vrsto izolacijskega materiala. V primeru, ko v določenem delu področja poljska jakost presega prebojno trdnost, moramo polje preoblikovati. Eden ključnih ukrepov, s katerim vplivamo na obliko polja, je postavljanje t. i. zaslona v dielektrik oziroma v izolacijsko telo skoznjika. Zaslone so tanke kovinske mrežice, ki predstavljajo ekvipotencialne ploskve, s katerimi oblikujejo polje.

### 5.5.2 Analiza problema in definiranje kriterijske funkcije

Skoznjiki so običajno sestavljeni iz enega samega izolacijskega materiala – araldita. Ko opisujemo njihovo strukturo, običajno pozabimo na prisotnost še enega izolacijskega medija, in sicer zraka. Dielektrična konstanta zraka ( $\epsilon_r = 1$ ) je mnogo nižja od dielektrične konstante araldita ( $\epsilon_r = 4,3$ ), kar je lahko v večini primerov razlog, da se velike obremenitve pojavljajo ravno v "slabšem" dielektriku. Na področjih, kjer je električno polje pravokotno na meji teh dveh materialov, je razdelitev električnega polja

v obratnem razmerju dielektričnih konstant opazovanih materialov. Seveda če upoštevamo še dejstvo, da je prebojna trdnost zraka desetkrat manjša kot prebojna trdnost araldita, nas ta dva dejstva napeljujeta k zaključku, da je lahko pojav višjih obremenitev oz. vrednosti električnega polja v zraku problematičen.

Obravnavani skoznjik pripada 24 kV opremi. Glede na standarde z obravnavanega področja smo izračune polja izvedli pri testni napetosti 125 kV. Diskretizirani model sestavlja okoli 9.000 KE, vsi izračuni pa so izvedeni s pomočjo programskega orodja EleFAnT2D [94]. Glede na sliko 5.36 lahko zaključimo, da oblika skoznjika s poenostavitvami omogoča 2D analizo, in sicer zaradi njegove osne simetričnosti [119].




Slika 5.37: a) Diskretizirani model skoznjika b) Izris električnega polja

Kritične obremenitve se glede na rezultate MKE analize obravnavanega problema dejansko pojavljajo na zunanji površini skoznjika, in sicer v zraku, kjer povišane vrednosti električne poljske jakosti lahko povzročijo pojav razelektritev in degradacijo materiala na tem mestu. Končni rezultat je seveda lahko preboj izolatorja.

V izogib opisani situaciji je zaželeno zmanjšanje električne poljske jakosti v kritičnih točkah danega izolacijskega sistema. Le-to lahko dosežemo z vstavitvijo zaslona v telo skoznjika. Z uporabo zaslona želimo polje oblikovati tako, da se večje obremenitve v smislu večjih električnih poljskih jakosti pojavljajo znotraj izolacijskega telesa, ki ima zelo veliko prebojno trdnost (30 MV/m). S tem razbremenimo okoliški zrak, katerega prebojna trdnost je neprimerno manjša (3 MV/m). Z ustrezno izbiro izolacijskega materiala, s katerim prevlečemo zaslon (obloga), lahko še dodatno znižamo vrednosti polja. Optimalna pozicija in velikost zaslona (definirana s parametri  $p_1$ ,  $p_2$  in  $p_3$ , prikazanimi na sliki 5.37 a) kot tudi izbira ustreznega izolacijskega materiala (dielektrične konstante obloge zaslona -  $p_4$ ) se lahko določi s pomočjo optimizacijskega algoritma, končni rezultat pa je večja zanesljivost delovanja samega izolatorja kot tudi sistema, katerega del je. Pri tem so izbrane omejitve parametrov oziroma prostora

preiskovanja naslednje:  $45 \leq p_1 \leq 55$  mm,  $118 \leq p_2 \leq 194$  mm,  $276 \leq p_3 \leq 352$  mm in  $2 \leq p_4 \leq 10$ .

Cilj optimizacije je doseči najnižjo vrednost električne poljske jakosti  $E$  v najbolj obremenjenem področju skoznjika. V tem primeru želimo, da gre vrednost kriterija  $f_E$  proti vrednosti 1 (slika 5.38 a). Pri optimizaciji po tem kriteriju pa je potrebno upoštevati še en kriterij, in sicer da naj razmerje  $E_1/E_2$  ostaja blizu vrednosti 1 oz. da gre vrednost pridružene KF  $f_r$  prav tako proti 1 (slika 5.38 b). To pomeni, da je preferirana mala razlika v vrednostih polja na meji materiala, ki pokriva zaslon (električno poljsko jakost v njem označimo z  $E_1$ ) ter telesa skoznjika ( $E_2$ ).




Slika 5.38: Kriterijska funkcija za: a) električno poljsko jakost in b) razmerje poljskih jakosti v dveh dielektrikih

Obe funkciji sta združeni v eno samo KF  $q$  z metodo utežnih vsot [26]:

$$q = 0,65f_E + 0,35f_r \quad (5.16)$$

kjer je višja prioriteta dana prvemu kriteriju. Omeniti je potrebno še, da sta funkcijski vrednosti  $f_E$  in  $f_r$  odšteti od vrednosti 1 z namenom prekvalifikacije optimizacijskega problema v problem minimizacije. Oblika združene KF  $q$  je prikazana na slikah 5.39 a in 5.39 b.



Slika 5.39: Oblika KF ( $p_1, p_4$  na sliki a ter  $p_1, p_2$  na sliki b so fiksirani)

Algoritem za optimizacijo skoznjika je grafično prikazan na sliki 5.14 (stran 100), vanj pa smo vključevali dve optimizacijski tehniki, in sicer DE in KADE.

### 5.5.3 Rezultati optimizacije

Rezultati optimizacije (tabela 5.6) so optimalne vrednosti optimizacijskih parametrov  $p_1$  do  $p_4$ , pri katerih zavzema KF  $q$  minimalno funkcijsko vrednost. V tem primeru minimiziramo vrednost polja v najbolj obremenjenem področju skoznjika. Dosežena minimalna vrednost električne poljske jakosti  $E = 2,73$  MV/m ustreza vrednosti KF  $f_E = 6,9 \times 10^{-3}$ , razmerje električnih poljskih jakosti  $E_1/E_2 = 0,87$  pa ustreza vrednosti  $f_r = 8,8 \times 10^{-3}$  tako, da vrednost združene KF  $q$  znaša  $7,57 \times 10^{-3}$ . Ta vrednost je bila uporabljena tudi kot zaustavitveni kriterij (*value to reach* – VTR) pri vseh desetih individualnih zagonih uporabljenih optimizacijskih algoritmov.

Tabla 5.6: Rezultati optimizacije skoznjika z uporabo algoritmov DE in KADE

$p_1$ [mm]	$p_2$ [mm]	$p_3$ [mm]	$p_4$	$E$ [MV/m]	$n_{feval}$ (DE)	$n_{feval}$ (KADE)	NS DE/KADE	R (%)
45	157,2	320,8	3,73	2,73	2735,2	1279,5	10/10	53,2

Oznaka  $n_{feval}$  predstavlja povprečno število cenitev dejanske KF, pridobljeno na osnovi desetih neodvisnih zagonov optimizacije, ter je prikazano za algoritem DE kot tudi algoritem KADE. Izraz "dejanska cenitev KF" se nanaša na algoritem KADE (ki uporablja Kriging modele za izračun aproksimirane vrednosti KF) in predstavlja tiste cenitve, kjer vrednost KF ocenjujemo posredno, in sicer z izračuni s pomočjo MKE modela skoznjika. NS predstavlja število uspešnih zagonov algoritma, tako da sta pri tem problemu oba optimizacijska algoritma dosegla enak rezultat, in sicer sta pri vsakem individualnem zagonu optimizacije konvergirala k iskanemu optimumu. Prednost algoritma KADE se kaže edino v tem, da je našel isto optimalno rešitev v več kot pol manj cenitvah dejanske KF, saj je prihranek v številu klicev MKE modela  $R = 53,2$  %. Ker so izračuni z MKE metodo časovno zahtevni in zahtevajo v konkretnem primeru okoli 3 minute za eno cenitev KF, lahko časovno zahtevnost Kriging modelov zanemarimo, saj njihova izdelava traja reda nekaj sekund. V praksi to pomeni, da je algoritem KADE prihranil okoli 50 % časa pri reševanju istega optimizacijskega problema in pod enakimi pogoji glede na algoritem DE.

Rezultati veljajo pri naslednji nastavitvah optimizacijskih algoritmov: strategija  $st. = 7$  (DE/rand/1/bin);  $Cr = 0,8$ ;  $F = 0,5$ ; velikost populacije  $NP = 20$  in  $NMPC = 150$  (parameter NMPC velja samo za algoritem KADE).

## 6. SKLEP

Pri izdelavi disertacije je bil narejen pregled stanja in novosti na področju optimizacij ter pregled in ugotavljanje učinkovitosti posameznih optimizacijskih tehnik na področju reševanja realnih tehniških problemov. Rdeča nit pri tej nalogi je bila iskanje učinkovite in zanesljive optimizacijske tehnike.

Pri pregledu rezultatov objav na področju optimizacij in aplikacij optimizacijskih algoritmov na različne tehniške probleme ter prav tako na podlagi pridobljenih lastnih izkušenj, se je kot eden primernejših algoritmov izkazal algoritem DE. Ta spada v skupino EA, ki temelji na nedeterminističnih procesih, zato je njegova pot iskanja optimuma praktično neponovljiva, vendar je kljub temu algoritem v večini primerov zmožen določiti globalni optimum.

Slaba stran DE, kot tudi drugih EA, je relativno počasna dinamika konvergence, kar z drugimi besedami pomeni veliko število iteracij – cenitev KF. V primerih, kadar KF ocenjujemo posredno, in sicer z uporabo različnih MKE modelov, lahko proces optimizacije z uporabo algoritma DE traja relativno dolgo časa. Kljub omenjeni slabi lastnosti algoritma, je njegova sposobnost poiskati globalni optimum, zadosten argument za njegovo uporabo. Pri tem je potrebno izpostaviti še, da ima tukaj algoritem DE večjo zanesljivost kot mnogi drugi EA.

Algoritem DE je relativno odprt za izvajanje različnih razširitev in dopolnitev. V tem kontekstu je bila izvedena razširitev iz algoritma za enokriterijsko optimizacijo v algoritem za večkriterijsko optimizacijo.

Ključna naloga algoritma DE pri vsaki aplikaciji je iskanje globalnega optimuma, pri tem pa si seveda želimo čim hitrejšo konvergenco optimizacijskega postopka. Izdelava optimizacijskega algoritma z izboljšano dinamiko konvergence predstavlja prvi izvirni znanstveni prispevek. V kontekstu odprtosti algoritma DE in težnji po njegovem izboljšanju, je bila izvedena dopolnitev algoritma DE s Kriging interpolacijsko metodo, ki

je služila kot podpora samemu optimizacijskemu algoritmu. Cilj dopolnitve DE oz. novonastalega algoritma KADE je bil izboljšanje dinamike konvergence oz. pohitritev optimizacijskega postopka in s tem izboljšanje praktičnosti in uporabnosti algoritma pri integracijah v algoritme za načrtovanje in identifikacijo parametrov. Različni primeri na standardnih testnih funkcijah kot tudi aplikacija algoritma KADE na realnem tehniškem primeru je pokazala, da razviti algoritem potrebuje za lociranje globalnega optimuma v povprečju polovico manj klicev dejanske KF v primerjavi s klasičnim algoritmom DE. V praksi to pomeni, da je tudi skrajšanje časa, ki je potreben za dokončanje optimizacijskega procesa, v približno enakem obsegu.

Pojem "elementi EEO" predstavlja širok nabor različnih električnih elementov in naprav, ki se uporabljajo za različne namene. Tako ima vsak posamezen element določene specifikacije. Ko omenjamo splošno optimizacijo elementov EEO je pri realizaciji algoritma za optimiranje ključnega pomena univerzalnost pri pristopu k reševanju optimizacijskega problema. Odprtost in prilagodljivost algoritma DE je tako botrovala izdelavi algoritma za načrtovanje električnih naprav in identifikacijo parametrov njihovih matematičnih modelov, ki omogoča reševanje direktnih kot tudi inverznih problemov. Drugi znanstveni prispevek je tako univerzalni algoritem za načrtovanje in identifikacijo parametrov, ki je orientiran predvsem na uporabo različnih programskih orodij za posredno cenitev KF optimizacijskega problema. Le-ta je odprt za implementacijo poljubnih evolucijskih optimizacijskih tehnik in omogoča široko namembnost. Poleg načrtovanja novih ter optimizacije obstoječih elementov EEO je zmožen prevzeti vlogo orodja za reševanje inverznih problemov, in sicer za identifikacijo parametrov poljubnega modela oz. njegovo uglaševanje. Teza naloge, da je možno modificirati mehanizme izbrane optimizacijske tehnike, tako da izboljšamo dinamiko konvergence optimizacijskega postopka, ter da je možno reševati raznorodne optimizacijske probleme na univerzalnem algoritmu za načrtovanje in identifikacijo parametrov, je tako potrjena.

Nadgradnja omenjenega algoritma v orodje za parametrično analizo omogoča nakazovanje tendence spreminjanja parametrov v primeru, če so le-ti odvisni od zunanjih vplivov na objekt, kot to velja za primer PO prenapetosti. Postopek zahteva koračno izvajanje identifikacije parametrov modela, in sicer individualno izvajanje za vsako posamezno meritev oz. spremembo stanja objekta, ki ima za posledico nereverzibilno spremembo njegove zgradbe oz. njegovih lastnosti. Iz pridobljenih optimalnih parametrov modela za vsako individualno meritev lahko z regresijo napovemo vrednosti parametrov za kasnejša, še neizvedena delovanja oz. stanja naprave. Orodje, ki omogoča napoved spremembe parametrov modela v odvisnosti od zunanjih vplivov na realnem objektu ali njegovih stanj, predstavlja tretji izvorni znanstveni prispevek.



## LITERATURA

- [1] P. Kitak, J. Pihler, I. Tičar, "Način krmiljenja potenciala v notranjosti VN izolacijskih elementov," *Zbornik CIREC, Zbornik CIGRÉ, Sedma konferenca slovenskih elektroenergetikov*, zv. 1, str. A3-7 - A3-10, Velenje, 2005.
- [2] J. Pihler, *Switchgear of electric power system*, University of Maribor, Faculty of Electrical Engineering and Computer Science, 2003.
- [3] P. Kitak, *Načrtovanje in optimizacija elementov stikalnih naprav z uporabo MKE ob parametrizaciji vhodnega podatkovnega algoritma*, Doktorska disertacija, Univerza v Mariboru – Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, Slovenija, 2006.
- [4] U. Pahner, *A General Design Tool for the Numerical Optimization of Electromagnetic Energy Transducers*, Katholieke Univesiteit Leuven – Facultiet Toegepaste Wetenschappen Arenbergkasteel, Haverlee, Belgium, 1998.
- [5] Z. Toroš, J. Pihler, G. Štumberger, A. Glotić, "Methods for determining the status of MV switching devices using minimum cost criterion," *IEEE Transactions on Power Delivery*, vol. 24, no. 2, pp. 664-671, 2009.
- [6] P. Kitak, I. Ticar, J. Pihler, A. Glotic, J. Popovic, O. Biro, K. Preis, "Application of the Hybrid Multiobjective Optimization Methods on the Capacitive Voltage Divider," *IEEE Transactions on Magnetics*, vol. 45, no. 3, pp. 1594-1597, 2009.
- [7] D. E. Cameron, J. H. Lang, D. Belanger, "The computer-aided design of variable reluctance generators," *Applied Power Electronics Conference and Exposition, 1992. APEC '92. Conference Proceedings 1992., Seventh Annual*, pp. 114-120, 1992.
- [8] A. P. Marsicano, C. E. Tavares, J. C. Oliveira, J. W. Resende, D. A. Andrade, I. Nord, "Genetic algorithms based technique for the optimization of 34.5 and 138 kV overhead lines power capability," *Transmission and Distribution Conference and Exposition: Latin America, 2008 IEEE/PES*, pp. 1-6, 2008.
- [9] O. A. Mohammed, "GA optimization in electrical devices," *Proceedings of the IEEE Antennas and Propagation Society International Symposium*, vol. 3, pp. 1696-1699, 1997.

- [10] O. A. Mohammed, "Genetic algorithms and their practical implementation strategies for design optimization of electrical devices," *Seminar on Advanced Computational Electromagnetics*, pp. 6.1-6-18, Tokyo, 1999.
- [11] D. Morinigo, O. Duque, M. A. Rodriguez, V. Vazquez, "Comparison of optimal shape design algorithm: tabu search and simulated annealing," *IEEE Mediterranean Electrotechnical Conference, MELECON 2006*, pp. 1170-1173, 2006.
- [12] B. Polajzer, G. Stumberger, J. Ritonja, D. Dolinar, "Variations of Active Magnetic Bearings Linearized Model Parameters Analyzed by Finite Element Computation," *IEEE Transactions on Magnetics*, vol. 44, no. 6, pp. 1534-1537, 2008.
- [13] R. K. Ursem, P. Vadstrup, "Parameter identification of induction motors using differential evolution," *The 2003 Congress on Evolutionary Computation, CEC '03*, vol. 2, pp. 790-796, 8-12, 2003.
- [14] M. Andriollo, L. Bolognese, G. Martinelli, A. Morini, A. Tortella, "Electromagnetic design improvement of a switched reluctance motor by a surface-current method procedure," *Electromotion*, vol. 8, no. 3, pp. 125-32, 2001.
- [15] K. A. Mendhurwar, V. K. Devabhaktuni, R. Raut, "A new computer-aided multi-dimensional device modeling algorithm based on binning concepts," *26<sup>th</sup> International Conference on Microelectronics, MIEL 2008*, pp. 477-480, 2008.
- [16] P. Siarry, Z. Michalewicz, *Advances in Metaheuristics for Hard Optimization*, Springer, 1 ed., 2007.
- [17] J. T. Kim, W. S. Kim, S. H. Kim, K. D. Choi, G.-W. Hong, H. G. Joo, S. Y. Hahn, "Optimization of transformer winding considering AC loss of BSCCO wire," *IEEE Transactions on Applied Superconductivity*, vol. 15, no. 2, pp. 1839-1842, 2005.
- [18] I. Ticar, P. Kitak, J. Pihler, "Design of new medium voltage indicator by means of electric field calculation," *Midem-journal of microelectronics, electronic components and materials*, vol. 32, no. 2, pp. 82-87, 2002.
- [19] P. Kitak, J. Pihler, I. Ticar, "Optimisation algorithm for the design of bushing for indoor SF6 switchgear applications," *IEE proc., Gener. transm. distrib.*, vol. 152, pp. 691-696, 2005.
- [20] T. Marcic, G. Stumberger, B. Stumberger, M. Hadziselimovic, P. Virtic, "Determining Parameters of a Line-Start Interior Permanent Magnet Synchronous Motor Model by the Differential Evolution," *IEEE Transactions on Magnetics*, vol. 44, no. 11, pp. 4385-4388, 2008.
- [21] H. K. Kim, J. K. Chong, K. Y. Park, "Differential evolution strategy for constrained global optimization and application to practical engineering problems," *IEEE Transactions on Magnetics*, vol. 43, no. 4, pp. 1565-1568, 2007.
- [22] P. Kitak, J. Pihler, I. Ticar, A. Stermecki, O. Biro, K. Preis, "Potential Control Inside Switch Device Using FEM and Stochastic Optimization Algorithm," *IEEE Transactions on Magnetics*, vol. 43, no. 4, pp. 1757-1760, 2007.

- [23] P. Kitak, J. Pihler, I. Ticar, A. Stermecki, C. Magele, O. Biro, K. Preis, "Use of an optimization algorithm in designing medium-voltage switchgear insulation elements," *IEEE Transactions on Magnetics*, vol. 42, no. 4, pp. 1347-1350, 2006.
- [24] K. Price, R. Storn, J. Lampinen, *Differential Evolution – A Practical Approach to Global Optimization*, Springer-Verlag, Berlin Heidelberg, 2005.
- [25] G. Papa, *Sočasno razvrščanje operacij in dodeljevanje enot z evolucijsko tehniko v postopku načrtovanja integriranih vezij*. Doktorska disertacija, Univerza v Ljubljani, Ljubljana, Slovenija, 2002.
- [26] C. Magele, T. Ebner, *Optimization in Electrical Engineering*, Institute for Fundamentals and Theory in Electrical Engineering, Technical University of Graz.
- [27] [http://www.stanford.edu/class/cs205a/notes\\_old/class\\_8.pdf](http://www.stanford.edu/class/cs205a/notes_old/class_8.pdf)
- [28] J. Andersson, "A survey of multiobjective optimization in engineering design," *Technical report LiTH-IKP-R-1097*, Department of Mechanical Engineering, Linköping University, Linköping, Sweden, 2000.
- [29] <http://cool.mines.edu/report/node3.html>
- [30] <http://trond.hjorteland.com/thesis/node26.html>
- [31] T. Robič, B. Filipič, "In search for an efficient parameter tuning method for steel casting," *Proceedings of the International Conference on Bioinspired Optimization Methods and their Applications - BIOMA 2004*, pp. 83-94, 2004.
- [32] <http://staff.science.nus.edu.sg/~phywjs/CZ5101/nrlec7.ppt>
- [33] <http://trond.hjorteland.com/thesis/node27.html>
- [34] <http://trond.hjorteland.com/thesis/node28.html>
- [35] T. Robič, B. Filipič, "Večkriterijsko optimiranje z genetskimi algoritmi in diferencialno evolucijo," *Delovno poročilo IJS-DP 9065*, Inštitut »Jožef Stefan«, Ljubljana, Slovenija, 2005.
- [36] C.-S. Tsou, S.-C. Chang, and P.-W. Lai, "Using crowding distance to improve multi-objective PSO with local search," in *Swarm Intelligence: Focus on Ant and Particle Swarm Optimization, chapter 5*, Itech Education, Vienna, Austria, 2007.
- [37] T. Robič, *Genetski algoritem za problem urnika*. Diplomsko delo, Ljubljana, 2002.
- [38] R. Storn and K. Price, "Minimizing the real functions of the ICEC'96 contest by differential evolution", *Proceedings of IEEE International Conference on Evolutionary Computation*, pp. 842 – 844, 1996.
- [39] D. Zaharie, "A multipopulation differential evolution algorithm for multimodal optimization," in *Proceedings of Mendel 2004, 10<sup>th</sup> International Conference on Soft Computing*, Brno, Czechoslovakia, pp. 17–22, 2004.
- [40] A. Taranenko, *Evolucijski algoritmi za posplošena barvanja grafov*. Magistrsko delo, Maribor, September 2003.

- [41] B. Dušej, *Optimizacija parametrov PID regulatorja enosmernega motorja z genetskim algoritmom*. Diplomsko delo, Univerza v Mariboru, Maribor, Slovenija, 2002.
- [42] K. Y. Lee, M. Al-Sharkawi, *Modern Heuristic Optimization Techniques: Theory And Application To Power Systems*, Fundamentals of Simulated Annealing, Wiley-Interscience, Hoboken, 2008.
- [43] G. C. Onwubolu, D. Davendra, *Differential Evolution: A Handbook for Global Permutation-Based Combinatorial Optimization (Studies in Computational Intelligence)*, Berlin: Springer-Verlag, 2009.
- [44] V. Feoktistov, *Differential Evolution: In Search of Solutions*, (Springer Optimization and Its Applications), Secaucus, NY, USA: Springer-Verlag New York, Inc., 2006.
- [45] T. Robic, B. Filipic, *DEMO: Differential Evolution for Multiobjective Optimization*, Lecture Notes in Computer Science, Springer Berlin/Heidelberg, 2005.
- [46] A. Glotić, P. Kitak, J. Pihler, I. Tičar, "Primerjava nekaterih evolucijskih algoritmov," *Zbornik šestnajste mednarodne Elektrotehniške in računalniške konference ERK 2007*, zv. B, str. 61-64, 24. – 26, 2007.
- [47] K. Deb, A. Pratap, S. Agarwal, T. Meyarivan, "A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, 6(2), pp. 181–197, 2002.
- [48] E. M. Montes, M. R. Sierra, and C. A. C. Coello: "Multi-Objective Optimization using Differential Evolution: A Survey of the State-of-the-Art", *Advances in Differential Evolution*, Springer, 2008.
- [49] M. Maximiano, M. A. Vega-Rodriguez, J. A. Gomez-Pulido, J. M. Sanchez-Perez, "Analysis of Parameter Settings for Differential Evolution Algorithm to Solve a Real-World Frequency Assignment Problem in GSM Networks," *The Second International Conference on Advanced Engineering Computing and Applications in Sciences*, pp. 77-82, 2008.
- [50] K. V. Price, "An introduction to differentialevolution," in *New ideas in optimization*, McGraw-Hill Ltd., UK, Maidenhead, UK, England, 1999.
- [51] A. M. Sutton, M. Lunacek and L. D. Whitley, "Differential evolution and Non-separability: Using selective pressure to focus search," *GECCO'07*, pp. 1428 – 1435, 2007.
- [52] L. V. Santana-Quintero, C. A. C. Coello, "An Algorithm Based on Differential Evolution for Multi-Objective Problems," *International Journal of Computational Intelligence Research*, vol. 1, no. 2, pp. 151–169, 2005.
- [53] T. Robič, B. Filipič, "Večkriterijska optimizacija z evolucijskimi algoritmi," *In Proceedings of the thirteenth International Electrotechnical and Computer Science Conference - ERK 2004*, Volume B, pp. 149-152, 2004.
- [54] V. L. Huang, P. N. Suganthan, A. K. Qin, S. Baskar, "Multiobjective differential evolution with external archive and harmonic distance-based diversity measure," *Technical Report*, Nanyang Technological University, 2005.

- [55] T. Tušar, *Design of an Algorithm for Multiobjective Optimization with Differential Evolution*. Magistersko delo, Univerza v Ljubljani, 2007
- [56] K. Zielinski and R. Laur, "Variants of Differential Evolution for Multi-Objective Optimization" in *Proceedings of the IEEE Symposium on Computational Intelligence in Multicriteria Decision Making (MCDM '07)*, pp. 91-98, Honolulu, HI, USA, 2007.
- [57] K. Zielinski, D. Peters, R. Laur, "Constrained Multi-Objective Optimization Using Differential Evolution," *Proceedings of the Third International Conference on Computational Intelligence, Robotics and Autonomous Systems - CIRAS 2005*, Singapore, 2005.
- [58] A. W. Iorio, X. Li, "Incorporating directional information within a differential evolution algorithm for multi-objective optimization," *Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation*, pp. 691-698, 2006.
- [59] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Publishing Company, Reading, Massachusetts, 1989.
- [60] J. D. Knowles, D. Corne, "Approximating the Nondominated Front Using the Pareto Archived Evolution Strategy," *Evolutionary Computation*, vol. 8, no. 2, pp. 149-172, 2000.
- [61] J. Brest, M. S. Maučec, "Population size reduction for the differential evolution algorithm," *Applied Intelligence*, vol. 29, no. 3, pp. 228-247, 2008.
- [62] J. Brest, S. Greiner, B. Boskovic, M. Mernik, V. Zumer, "Self-Adapting Control Parameters in Differential Evolution: A Comparative Study on Numerical Benchmark Problems," *IEEE Transactions on Evolutionary Computation*, vol. 10, no. 6, pp. 646-657, 2006.
- [63] J. Zgraja, "The optimization of induction heating system based on multiquadratic function approximation," *COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, Vol. 24 Iss: 1, pp. 305-313, 2005.
- [64] Y. Wu, "Optimization Design of Special Vehicle Frame Based on Kriging Method," *Second International Conference on Information and Computing Science*, vol. 4, pp. 236-239, 2009.
- [65] M. Kobal, K. Eler, P. Simončič, H. Kraigher, "Uporaba geostatističnega modela za predstavitev interakcij v rizoferi," *Studia Forestalia Slovenica*, No. 135, pp. 41-46, 2009.
- [66] W. C. M. van Beers, *Kriging metamodeling for simulation*. PhD-Thesis, University of Tilburg, The Netherlands, 2005.
- [67] J. P. C. Kleijnen, "Kriging Metamodeling in Simulation: A Review," Discussion Paper, Tilburg University, Center for Economic Research, 2007.
- [68] M. H. A. Bonte, A. H. van den Boogaard, J. Huétink, "Solving optimisation problems in metal forming using Finite Element simulation and metamodeling techniques," *Automatic Process Optimization in Materials Technology*, pp. 242-251, 2005.

- [69] Y. Xie, X. Xu, Y. Ma, "Optimization of Sheet Flanging Forming Based on Kriging Metamodel," *International Conference on Artificial Intelligence and Computational Intelligence*, vol. 3, pp. 282-286, 2009.
- [70] G. Lei, K. R. Shao, Y. Guo, J. Zhu, J. D. Lavers, "Sequential Optimization Method for the Design of Electromagnetic Device," *IEEE Transactions on Magnetics*, vol. 44, no. 11, pp. 3217-3220, Nov. 2008.
- [71] G. Lei, K. R. Shao, Y. Guo, J. Zhu, J. D. Lavers, "Improved Sequential Optimization Method for High Dimensional Electromagnetic Device Optimization," *IEEE Transactions on Magnetics*, vol. 45, no. 10, pp. 3993-3996, Oct. 2009.
- [72] B. Lukasik, K. F. Goddard, M. D. Rotaru, J. K. Sykulski, "Kriging assisted design of a synchronous superconducting generator with YBCO windings," *17th Conference on the Computation of Electromagnetic Fields COMPUMAG 2009*, pp. 310-311, Brazil, 2009.
- [73] L. Willmes, T. Baeck, Y. Jin, and B. Sendhoff, "Comparing neural networks and kriging for fitness approximation in evolutionary optimization," *Proceedings of IEEE Congress on Evolutionary Computation*, pp. 663-670, 2003.
- [74] M. Bhattacharya, "Surrogate based Evolutionary Algorithm for Design Optimization," *World Academy of Science Engineering and Technology*, Vol. 10, pp. 52-57, 2005.
- [75] L. Lebensztajn, C. A. R. Marretto, M. C. Costa, J. L. Coulomb, "Kriging: a useful tool for electromagnetic device optimization," *IEEE Trans. on Magnetics*, vol. 40, no. 2, pp. 1196-1199, 2004.
- [76] R. Yuan, B. Guangchen, "Comparison of Neural Network and Kriging Method for Creating Simulation-Optimization Metamodels," *Eighth IEEE International Conference on Dependable, Autonomic and Secure Computing*, pp. 815-821, 2009.
- [77] S. L. Ho, S. Y. Yang, G. Z. Ni, H. C. Wong, "A response surface methodology based on improved compactly supported radial basis function and its application to rapid optimizations of electromagnetic devices," *IEEE Trans. on Magnetics*, vol. 41, no. 6, pp. 2111-2117, 2000.
- [78] T. Ebner, C. Magele, B. R. Brandstatter, K. R. Richter, "Utilizing feed forward neural networks for acceleration of global optimization procedures," *IEEE Trans. on Magnetics*, vol. 34, no. 5, pp. 2928-2931, 1998.
- [79] K. S. Won; T. Ray, "Performance of kriging and cokriging based surrogate models within the unified framework for surrogate assisted optimization," *Congress on Evolutionary Computation, CEC2004*, vol.2, pp. 1577- 1585, 2004.
- [80] S. N. Lophaven, H. B. Nielsen, J. Sondergaard, *DACE: A MATLAB Kriging Toolbox Version 2.0*, Tech. Univ. Denmark, Copenhagen, Tech. Rep. IMM-TR-2002-12, 2002.
- [81] <http://www2.imm.dtu.dk/~hbn/dace/>

- [82] L. Idoumghar, M. Melkemi, R. Schott, "A Novel Hybrid Evolutionary Algorithm for Multi-modal Function Optimization and Engineering Applications," *Proceeding of The 13<sup>th</sup> IASTED, International Conference on Artificial Intelligence and Soft Computing (ASC 2009)*, pp. 87-93, Palma de Mallorca, Spain, 2009.
- [83] D. Karaboga, B. Basturk, "A Powerful And Efficient Algorithm For Numerical Function Optimization: Artificial Bee Colony (ABC) Algorithm," *Journal of Global Optimization*, Vol. 39 , Iss. 3, pp. 459-471, Springer Netherlands, 2007.
- [84] J. Yan, Q. Ling, D. Sun, "A Differential Evolution with Simulated Annealing Updating Method," *International Conference on Machine Learning and Cybernetics*, pp. 2103-2106, 2006.
- [85] A. Glotic, J. Pihler, P. Kitak, I. Ticar, "Ugotavljanje vpliva kontrolnih parametrov na algoritem diferenčne evolucije s Kriging podporo," *Zbornik devetnajste mednarodne Elektrotehniške in računalniške konference ERK 2010*, zv. B, str. 123-126, Portorož, Slovenija, 2010.
- [86] O. Biro, K. R. Richter, *CAD in Electromagnetism*, Institute for fundamentals and theory in electrical engineering, University of Technology, Graz, 1991.
- [87] P. P. Silvester. R. L. Ferrari, *Finite elements for electrical engineers*, Cambridge University Press, 1990.
- [88] P. Seers, *Spark ignition: An Experimental and Numerical Investigation*. Doktorska disertacija, University of Texas, Austin, 2003.
- [89] A. Larsson, H. Tang and V. Scuka, "Mathematical simulation of a gas discharge protector using ATP-EMTP," *Proc. Int. Symp. On EMC*, pp. 315-320, Rome, Italy 1996.
- [90] S. Singha, M. J. Thomas, "Toepler's Spark Law in a GIS with Compressed SF<sub>6</sub>-N<sub>2</sub> Mixture," *IEEE Trans. Dielectrics Electrical Insulation*, Vol. 10, No. 3, pp. 498-505, 2003.
- [91] P. H. Schavenmaker, L. van der Sluis, "An Improved Mayr-Type Arc Model Based on Current Zero Measurements," *IEEE Trans. Power Del.*, Vol. 15, No. 2, pp. 580-584, 2000.
- [92] B. Erjavec, J. Pihler, M. Trlep, "Načrtovanje zaščitnih iskrih visokonapetostnih kompozitnih izolatorjev s pomočjo izračuna električnega polja," *Elektroteh. vestn.*, let. 69, št. 5, str. 273-278, 2002.
- [93] <http://www.izoelektro.com/>
- [94] *EleFAtT software tool*, Graz, Austria: Institute for Fundamentals and Theory in Electrical Engineering, University of Technology, Graz, 2000.
- [95] A. Glotic, "Design optimization of a post composite insulator using differential evolution and genetic algorithm," *IX international PhD workshop, Wisła, 20-23 October 2007, Conference Archives PTETIS*, vol. 23, pp. 189-193, 2007.
- [96] W. T. Grondzik, A. G. Kwok, B. Stein, J. S. Reynolds, *Mechanical and Electrical Equipment for Buildings*, John Wiley & Sons, 2007.

- [97] M. Kasumović, *Numerički proračun elektromagnetnog i temperaturnog polja u transformatoru*. Magistersko delo, Univerza v Tuzli, 2005.
- [98] J. Driesen, G. Deliege, R. Belmans and K. Hameyer, "Coupled Thermo-Magnetic Simulation of a Foil-Winding Transformer Connected to a Nonlinear Load", *IEEE Transactions on Magnetics*, vol. 36, no. 4, pp. 1381-1385, 2000.
- [99] J. Driesen, R. Belmans, and K. Hameyer, "Computation algorithms for efficient coupled electromagnetic-thermal device simulation," *IEE Proceedings-Science, Measurement and Technology*, vol. 149, pp. 67-72, 2002.
- [100] J. Driesen, R. Belmans, K. Hameyer, "Methodologies for Coupled Transient Electromagnetic-Thermal Finite Element Modeling of Electrical Energy Transducers," *IEEE Transactions on Industry Applications*, vol. 38, no. 5, pp. 1244-1250, 2002.
- [101] V. Mađarević, I. Kapetanović, M. Tešanović, M. Kasumović, "Numerical calculation of thermal field distribution in oil immersed power transformer: a comparison of methods," *Proceedings of the 6th IASME/WSEAS international conference on Energy & environment*, pp. 353-358, 2011.
- [102] *FLUX2D*, Version 7.60: CAD package for electromagnetic and thermal analysis using finite elements, CEDRAT, France, 2001.
- [103] J. Fish, T. Belytschko, *A first course in finite elements*, Wiley, 2007.
- [104] M. F. Cohen, J. R. Wallace, *Radiosity and realistic image synthesis*, Morgan Kaufmann, 2002.
- [105] A. F. Mills, *Basic Heat and Mass Transfer*, University of California: Prentice Hall, 1999.
- [106] M. S. Zhdanov, *Geophysical Electromagnetic Theory and Methods*, Elsevier Science, 2009.
- [107] J. Ribič, *Prenapetostna zaščita zgradb*. Magistrsko delo, Univerza v Mariboru, Maribor, 2006.
- [108] D. Respondek, R. B. Standler, "Surge protection for electronic equipment," *Compliance Engineering European Edition*, pp. 29-35, 1995.
- [109] A. Pregelj, F. Breclj, A. Pirh in V. Murko, "Tehnološke zahtevnosti pri izdelavi plinskega odvodnika," *Strojniški vestnik*, let. 49, št. 2, str. 119 – 126, 2003.
- [110] IEEE W.G. 3.4.11 of surge protective devices committee, *IEEE Trans. Power Del.*, vol. 11, no. 1, pp. 301–309, 1992.
- [111] P. Pinceti and M. Giannettoni, "A simplified model for zinc oxide surge arresters," *IEEE Trans. Power Del.*, vol. 14, no. 2, pp. 393–398, 1999.
- [112] H. J. Li, S. Birlasekaran, and S. S. Choi, "A parameter identification technique for metal-oxide surge arrester models," *IEEE Trans. Power Del.*, vol. 17, no. 3, pp. 736–741, 2002.



- [113] J. A. Martinez and D. W. Dubarak, "Parameter determination for modeling system transients—Part V: Surge arresters," *IEEE Trans. Power Del.*, vol. 20, no. 3, pp. 2073–2078, 2005.
- [114] A. Larrson, V. Scuka, K. Borgeest, and J. L. ter Haseborg, "Numerical simulation of gas discharge protector - A review," *IEEE Trans. Power Del.*, vol. 14, no. 2, pp. 405–410, 1999.
- [115] T. Marošević, "A choice of norm in discrete approximation," *Mathematical Communications*, Vol. 1, No. 2, pp. 147–152, 1996.
- [116] A. Glotic, J. Pihler, J. Ribic, G. Stumberger, "Determining a Gas-Discharge Arrester Model's Parameters by Measurements and Optimization," *IEEE Transactions on Power Delivery*, vol. 25, no. 2, pp. 747-754, 2010.
- [117] Z. Toroš, *Hibridni kazalci kakovosti električne energije v elektroenergetskem distribucijskem omrežju*. Doktorska disertacija, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, 2010.
- [118] <http://www.uradni-list.si/1/content?id=99178>
- [119] A. Glotic, P. Kitak, J. Pihler, I. Ticar, "Determining optimal size, position and covering material for a bushing shield," *Journal of energy technology*, vol. 2, iss. 2, str. 55-64, 2009.



## OSEBNA BIBLIOGRAFIJA

ADNAN GLOTIĆ [28431]

Osebna bibliografija za obdobje 2004-2011

### ČLANKI IN DRUGI SESTAVNI DELI

#### 1.01 Izvirni znanstveni članek

1. KITAK, Peter, POPOVIĆ, Jelena, GLOTIĆ, Adnan. Thermal analysis of eddy currents phenomena based on independent parametric simulation model. Prz. Elektrotech., 2008, vol. 84, no. 12, str. 174-176. [COBISS.SI-ID [12913942](#)], [[WoS](#), št. citatov do 7. 4. 2011: 0, brez avtocitatov: 1, normirano št. citatov: 1]
2. KITAK, Peter, TIČAR, Igor, PIHLER, Jože, GLOTIĆ, Adnan, POPOVIĆ, Jelena, BIRÓ, Oszkar, PREIS, Kurt. Application of the hybrid multiobjective optimization methods on the capacitive voltage divider. IEEE trans. magn., Mar. 2009, vol. 45, no. 3, str. 1594-1597. <http://dx.doi.org/10.1109/TMAG.2009.2012751>, doi: [10.1109/TMAG.2009.2012751](https://doi.org/10.1109/TMAG.2009.2012751). [COBISS.SI-ID [13078294](#)], [[JCR](#), [WoS](#), št. citatov do 7. 4. 2009: 0, brez avtocitatov: 0, normirano št. citatov: 0]
3. TOROŠ, Zvonko, PIHLER, Jože, ŠTUMBERGER, Gorazd, GLOTIĆ, Adnan. Methods for determining the status of MV switching devices using minimum cost criterion. IEEE trans. power deliv.. [Print ed.], Apr. 2009, vol. 24, no. 2, str. 664-671, doi: [10.1109/TPWRD.2009.2014476](https://doi.org/10.1109/TPWRD.2009.2014476). [COBISS.SI-ID [13164054](#)], [[JCR](#), [WoS](#), št. citatov do 8. 12. 2010: 0, brez avtocitatov: 0, normirano št. citatov: 0]
4. GLOTIĆ, Adnan, KITAK, Peter, PIHLER, Jože, TIČAR, Igor. Determining optimal size, position and covering material for a bushing shield. Journal of energy technology, June 2009, vol. 2, iss. 2, str. 55-64. [COBISS.SI-ID [13385238](#)]
5. GLOTIĆ, Adnan, PIHLER, Jože, RIBIČ, Janez, ŠTUMBERGER, Gorazd. Determining a gas-discharge arrester model's parameters by measurements and optimization. IEEE trans. power deliv.. [Print ed.], Apr. 2010, vol. 25, no. 2, str. 747-754, doi: [10.1109/TPWRD.2009.2038386](https://doi.org/10.1109/TPWRD.2009.2038386). [COBISS.SI-ID [13994774](#)], [[JCR](#), [WoS](#), št. citatov do 7. 5. 2010: 0, brez avtocitatov: 0, normirano št. citatov: 0]

## 1.08 Objavljeni znanstveni prispevek na konferenci

6. TIČAR, Igor, PIHLER, Jože, KITAK, Peter, GLOTIĆ, Adnan. Modelling of a bushing by the use of shield and material optimization. V: MUKHOPADHYAY, Subhas Chandra (ur.). Proceedings of the fourth International Conference on Computational Intelligence, Robotics and Autonomous Systems, Massey University, Palmerston North, New Zealand, 28th-30th November, 2007. CIREs 2007 : proceedings of the fourth International Conference on Computational Intelligence, Robotics and Autonomous Systems, Massey University, Palmerston North, New Zealand, 28th-30th November, 2007. New Zealand: Institute of Information Science and Technology, cop. 2007, str. 295-300. [COBISS.SI-ID [11945494](#)]

7. GLOTIĆ, Adnan. Design optimization of a post composite insulator using differential evolution and genetic algorithm. V: IX international PhD workshop, Wisła, 20-23 October 2007. OWD '2007 : IX international PhD workshop, Wisła, 20-23 October 2007, (Conference Archives PTETIS, vol. 23). [s. l.: s. n.], 2007, str. 189-193. [COBISS.SI-ID [11875350](#)]

8. GLOTIĆ, Adnan, PIHLER, Jože, KITAK, Peter, TIČAR, Igor. Shape optimization of a post composite insulator. V: BABUDER, Maks (ur.). Proceedings. Ljubljana: Faculty of Electrical Engineering: Elektroinštitut Milan Vidmar, 2007, 5 f. [COBISS.SI-ID [11599382](#)]

9. GLOTIĆ, Adnan, KITAK, Peter, PIHLER, Jože, TIČAR, Igor. Primerjava nekaterih evolucijskih algoritmov. V: ZAJC, Baldomir (ur.), TROST, Andrej (ur.). Zbornik Šestnajste mednarodne Elektrotehniške in računalniške konference ERK 2007, 24. -26. september 2007, Portorož, Slovenija. Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2007, zv. B, str. 61-64. [COBISS.SI-ID [11715350](#)]

10. GLOTIĆ, Adnan, KITAK, Peter, PIHLER, Jože, TIČAR, Igor. Electrothermal FEM analysis of an activated arcing horn. V: The 13th International IGTE Symposium on Numerical Field Calculation in Electrical Engineering [September 21 to September 24, 2008, Graz, Austria] : Proceedings. Graz: Verlag der Technischen Universität, 2008, str. 40-43. [COBISS.SI-ID [13079062](#)]

11. GLOTIĆ, Adnan, PIHLER, Jože, KITAK, Peter, POPOVIĆ, Jelena. Realizacija predprocesorja za programsko orodje EleFAnT3D. V: ZAJC, Baldomir (ur.), TROST, Andrej (ur.). Zbornik sedemnajste mednarodne Elektrotehniške in računalniške konference ERK 2008, 29. september - 1. oktober 2008, Portorož, Slovenija, (Zbornik ... Elektrotehniške in računalniške konference ERK ...). Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2008, zv. A, str. 350-353. COBISS.SI-ID [12669462](#)]

12. KITAK, Peter, OGRIZEK, Peter, TIČAR, Igor, PIHLER, Jože, GLOTIĆ, Adnan, POPOVIĆ, Jelena. Primerjava optimizacijskih algoritmov PSO in DE na modelu indikatorja napetosti. V: ZAJC, Baldomir (ur.), TROST, Andrej (ur.). Zbornik sedemnajste mednarodne Elektrotehniške in računalniške konference ERK 2008, 29. september - 1. oktober 2008, Portorož, Slovenija, (Zbornik ... Elektrotehniške in računalniške konference ERK ...). Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2008, zv. A, str. 358-361. [COBISS.SI-ID [12679958](#)]

13. KAPETANOVIĆ, Izudin, SARAJLIĆ, Nermin, TEŠANOVIĆ, Majda, KASUMOVIĆ, Mensur, PIHLER, Jože, GLOTIĆ, Adnan. Različiti pristupi modelovanju termičkih procesa kod trofaznih uljnih energetskih transformatorja = Different approaches in modeling of thermal processes in three phase oil imersed power transformer. V: IX bosansko hercegovačko savjetovanje, Neum 27.09-01.10.2009 : BH K CIGRÉ Proceedings. [S.l.: CIGRÉ, 2009], 7 str. [COBISS.SI-ID [13531926](#)]

14. KAPETANOVIĆ, Izudin, SARAJLIĆ, Nermin, TEŠANOVIĆ, Majda, KASUMOVIĆ, Mensur, PIHLER, Jože, GLOTIĆ, Adnan. Different hot-spot and top-oil temperature models for monitoring of transformers. V:

EKINOVIĆ, Sabahudin (ur.), VIVANCOS CALVET, Joan (ur.), YALÇIN, Senay (ur.). 13th International Research/Expert Conference Trends in the Development of Machinery and Associated Technology TMT 2009, 16-21 October 2009, Hammamet, Tunisia. Trends in the development of machinery and Associated technology : proceedings, (TMT Proceedings). Zenica: Faculty of Mechanical Engineering [etc.], 2009, str. 445-448, ilustr. [COBISS.SI-ID [13773078](#)]

**15.** GLOTIĆ, Adnan, PIHLER, Jože. Umerjanje enosmerne preskusne proge v močnostnem laboratoriju. V: ZAJC, Baldomir (ur.), TROST, Andrej (ur.). Zbornik Osemnajste mednarodne elektrotehniške in računalniške konference - ERK 2009, 21-23. september 2009, Portorož, Slovenija. Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2009, zv. A, str. 399-402. [COBISS.SI-ID [13491734](#)]

**16.** KITAK, Peter, TIČAR, Igor, PIHLER, Jože, GLOTIĆ, Adnan. Multi-objective optimization of a bushing with dynamic population PSO algorithm. V: The 14th International IGTE Symposium on Numerical Field Calculation in Electrical Engineering [September 19 to September 22, 2010, Graz, Austria] : Proceedings. Graz: Verlag der Technischen Universität, 2010, str. 479-483. COBISS.SI-ID [14847766](#)]

**17.** KITAK, Peter, GLOTIĆ, Adnan, TIČAR, Igor. Primerjava različnih strategij optimizacijskega algoritma diferenčne evolucijena testnih funkcijah in realnem problemu. V: ZAJC, Baldomir (ur.), TROST, Andrej (ur.). Zbornik devetnajste mednarodne Elektrotehniške in računalniške konference ERK 2010, Portorož, Slovenija, 20.-22. september 2010, (Zbornik ... Elektrotehniške in računalniške konference ERK ...). Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2010, zv. A, str. 488-491. [COBISS.SI-ID [14488086](#)]

**18.** GLOTIĆ, Adnan, PIHLER, Jože, KITAK, Peter, TIČAR, Igor. Ugotavljanje vpliva kontrolnih parametrov na algoritem diferenčne evolucije s Kriging podporo. V: ZAJC, Baldomir (ur.), TROST, Andrej (ur.). Zbornik devetnajste mednarodne Elektrotehniške in računalniške konference ERK 2010, Portorož, Slovenija, 20.-22. september 2010, (Zbornik ... Elektrotehniške in računalniške konference ERK ...). Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2010, zv. B, str. 123-126. [COBISS.SI-ID [14488342](#)]

### **1.09 Objavljeni strokovni prispevek na konferenci**

**19.** GLOTIĆ, Adnan, ŠKORJANC, Sašo, ŠTUMBERGER, Gorazd, VORŠIČ, Jože. Calculation of the electromagnetic field of conductors. V: International colloquium Power Frequency Elelctromagnetic Fields ELF EMF, 03-04 June 2009, Sarajevo, BiH. Power frequency electromagnetic fields ELF EMF : international colloquium. [S. l.: s. n.], 2009, paper 48, [10] f. [COBISS.SI-ID [13363734](#)]

### **1.12 Objavljeni povzetek znanstvenega prispevka na konferenci**

**20.** KITAK, Peter, TIČAR, Igor, PIHLER, Jože, GLOTIĆ, Adnan, POPOVIĆ, Jelena, BIRÓ, Oszkar, PREIS, Kurt. Application of the hybrid multi-objective optimization methods on the capacitive voltage divider. V: 13th Biennial IEEE Conference on Electromagnetic Field Computation, May 11-15, 2008, Athens, Greece. Proceedings. [Piscataway]: IEEE, 2008, str. 209. [COBISS.SI-ID [12542230](#)]

**21.** GLOTIĆ, Adnan, PIHLER, Jože, KITAK, Peter, TIČAR, Igor. Kriging assisted determination of the optimal geometry and covering material for a bushing shield. V: 14th biennial IEEE conference on electromagnetic field computation, May 9-12, 2010, Chicago IL, USA. CEFC 2010. Piscataway: IEEE, cop. 2010, 1 str. [COBISS.SI-ID [14269974](#)]

22. KITAK, Peter, GLOTIĆ, Adnan, TIČAR, Igor, PIHLER, Jože. Multiobjective optimization for determination of the electrothermal parameters in switchgear cell housing. V: 14th biennial IEEE conference on electromagnetic field computation, May 9-12, 2010, Chicago IL, USA. CEFC 2010. Piscataway: IEEE, cop. 2010, 1 str. [COBISS.SI-ID [14269718](#)]

## MONOGRAFIJE IN DRUGA ZAKLJUČENA DELA

### 2.11 Diplomsko delo

23. GLOTIĆ, Adnan. Umerjanje enosmerne močnostne proge v laboratoriju ICEM : diplomsko delo visokošolskega strokovnega študijskega programa, (Fakulteta za elektrotehniko, računalništvo in informatiko, Diplomsko dela visokošolskega strokovnega študija). Maribor: [A. Glotić], 2004. IX, 68 f., ilustr. [COBISS.SI-ID [8883990](#)]

24. GLOTIĆ, Adnan. Uporaba različnih zaslonov znotraj izolacijskih elementov za oblikovanje električnega polja : diplomsko naloga univerzitetnega študijskega programa, (Fakulteta za elektrotehniko, računalništvo in informatiko, Diplomsko dela univerzitetnega študija). Maribor: [A. Glotić], 2006. X, 102 f., ilustr. [COBISS.SI-ID [10833430](#)]

### 2.12 Končno poročilo o rezultatih raziskav

25. FLUHER, Bogdan, GLOTIĆ, Adnan, KITAK, Peter, PIHLER, Jože, STEGNE, Marjan, TIČAR, Igor, VORŠIČ, Jože, VORŠIČ, Žiga, DEŽELAK, Klemen, RIBIČ, Janez, SEME, Sebastijan, ŠTUMBERGER, Gorazd, VOH, Jurček. Izbira izolacijskih medijev v srednjenapetostnih celicah za distribucijska postrojenja in novih ločilnih stikal : (končno poročilo). Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2009. 159 str., ilustr. [COBISS.SI-ID [13363222](#)]

26. DEŽELAK, Klemen, SEME, Sebastijan, ŠTUMBERGER, Gorazd, GLOTIĆ, Adnan, PIHLER, Jože, RIBIČ, Janez, STEGNE, Marjan, VOH, Jurček, VORŠIČ, Jože. Vpliv sončne elektrarne z razsmerniškim vezjem na distribucijsko omrežje : končno poročilo o študiji. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2010. 117 str., ilustr. [COBISS.SI-ID [14707222](#)]

### 2.13 Elaborat, predštudija, študija

27. BUTINAR, Branko, KORAK, Andrej, PIHLER, Jože, VORŠIČ, Jože, DEŽELAK, Klemen, GLOTIĆ, Adnan, RIBIČ, Janez, SEME, Sebastijan, STEGNE, Marjan, ŠTUMBERGER, Gorazd, VOH, Jurček, VORŠIČ, Žiga. Kvantifikacija zanesljivosti vključitve objektov v omrežje upošteva integralne kriterije : [študijska naloga]. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2007. 172 str., ilustr. [COBISS.SI-ID [12187670](#)]

28. KORAK, Andrej, SEME, Sebastijan, ŠTUMBERGER, Gorazd, VORŠIČ, Jože, DEŽELAK, Klemen, GLOTIĆ, Adnan, ORGULAN, Andrej, PIHLER, Jože, RIBIČ, Janez, STEGNE, Marjan, VOH, Jurček. Razpršena proizvodnja iz obnovljivih virov : končno poročilo o izvajanju študije. Maribor: UM FERI, Laboratorij za energetiko, 2007. 182 str., ilustr. [COBISS.SI-ID [11896854](#)]

29. ŠTUMBERGER, Gorazd, JAKL, Franc, ORGULAN, Andrej, RIBIČ, Janez, DEŽELAK, Klemen, SEME, Sebastijan, LAMPRET, Ernest, PIHLER, Jože, VORŠIČ, Jože, GLOTIČ, Adnan, STEGNE, Marjan, VOH, Jurček. Optimalna razporeditev vodnikov : končno poročilo : [študijska naloga za ELEKTRO-SLOVENIJA]. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, Laboratorij za energetiko, 2008. XVII, 134 str., graf. prikazi. [COBISS.SI-ID [12743190](#)]
30. VORŠIČ, Jože, BUTINAR, Branko, PIHLER, Jože, RIBIČ, Janez, VOH, Jurček, DEŽELAK, Klemen, GLOTIČ, Adnan, KONJIČ, Tatjana, KORAK, Andrej, STEGNE, Marjan, ŠTUMBERGER, Gorazd, VORŠIČ, Žiga. Razvoj programske opreme za verjetnostne izračune stanj prenosnega omrežja. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, Laboratorij za energetiko, 2008. 172 str., graf. prikazi. COBISS.SI-ID [13098518](#)
31. HERGA, Srečko, RIBIČ, Janez, VOH, Jurček, VORŠIČ, Jože, BUTINAR, Branko, DEŽELAK, Klemen, FLUHER, Bogdan, GLOTIČ, Adnan, KORAK, Andrej, PIHLER, Jože, SEME, Sebastijan, STEGNE, Marjan, ŠTUMBERGER, Gorazd, VORŠIČ, Žiga. Verjetnostna analiza zanesljivosti oskrbe z električno energijo. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2009. 150 str., graf. prikazi, ilustr. [COBISS.SI-ID [13725206](#)]
32. KOŽELJ, Darko, ORGULAN, Andrej, SEME, Sebastijan, ŠTUMBERGER, Gorazd, VOH, Jurček, VORŠIČ, Jože, VORŠIČ, Žiga, DEŽELAK, Klemen, FLUHER, Bogdan, GLOTIČ, Adnan, PIHLER, Jože, RIBIČ, Janez, STEGNE, Marjan. Hranilniki energije kot črpalne elektrarne. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2010. 100 str., graf. prikazi, ilustr. [COBISS.SI-ID [14576406](#)]
33. FLUHER, Bogdan, GLOTIČ, Adnan, KITAK, Peter, PIHLER, Jože, STEGNE, Marjan, TIČAR, Igor, VORŠIČ, Jože, VORŠIČ, Žiga, DEŽELAK, Klemen, RIBIČ, Janez, SEME, Sebastijan, ŠTUMBERGER, Gorazd, VOH, Jurček. Vloga varovalk v srednjenapetostnih distribucijskih postrojenjih : (končno poročilo). Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2010. X, 150 str., graf. prikazi, ilustr. [COBISS.SI-ID [14720278](#)]

## IZVEDENA DELA (DOGODKI)

### 3.14 Predavanje na tuji univerzi

34. GLOTIČ, Adnan. Određivanje parametra modela plinskog odvodnika pomoću algoritma diferencne evolucije : [predavanje], Univerzitet u Tuzli, Fakultet elektrotehnike, Tuzla, 18. 4. 2008. Tuzla: Fakultet elektrotehnike, 2008. [COBISS.SI-ID [12325398](#)]
35. GLOTIČ, Adnan. Upotreba interpolacijske Kriging metode u svrhu postizanja računsko efiksne optimizacije : predavanje na Univerzitetu u Tuzli, Fakultet elektrotehnike, Tuzla, 23. 12. 2010. Tuzla: Fakultet elektrotehnike, 2010. [COBISS.SI-ID [14709782](#)]

Izpis bibliografskih enot: vse bibliografske enote

Izbrani format bibliografske enote: ISO 690

Vir bibliografskih zapisov: Vzajemna baza podatkov COBISS.SI/COBIB.SI, 12. 4. 2011

Datum ažuriranja baze JCR (letno): 18. 8. 2010

Datum ažuriranja povezav med zapisi v COBIB.SI in WoS ter števila citatov (mesečno): 7. 4. 2011





## PRILOGA

Tabela A.1: Rezultati optimizacije konfiguracije omrežja v povezavi z zanesljivostjo in stroški

Kriterij $C$ (p.u.)	Kriterij $1-Q$ (p.u.)	$r_{kb}$	$r_{vz}$	$t_r$ (ur)	$S_{Ne}$ (€)	$S_{Na}$ (€)	$S_v$ (€)	$V$ (€)	$C$ (€)	SAIFI <sub>Ne</sub>	SAIDI <sub>Ne</sub> (ur)	SAIFI <sub>Na</sub>	SAIDI <sub>Na</sub> (ur)	$Q$ (p.u.)
0,5292	0,8025	0,2100	0,5101	29,87	37599,6	6516,8	64831,8	3874,9	112823,1	3,306	7,152	0,483	2,477	0,1975
0,5301	0,8001	0,2122	0,5101	30,86	37652,1	6476,0	65045,7	3853,4	113027,2	3,296	7,139	0,481	2,463	0,1999
0,5356	0,7858	0,2239	0,5102	21,29	37434,4	6267,0	66162,1	4330,6	114194,2	3,243	7,038	0,467	2,390	0,2142
0,5371	0,7806	0,2298	0,5100	37,58	37953,3	6173,3	66702,3	3693,9	114522,8	3,215	7,034	0,461	2,355	0,2194
0,5381	0,7764	0,2323	0,5102	30,17	37750,3	6125,4	66950,0	3896,9	114722,7	3,205	6,983	0,458	2,339	0,2236
0,5430	0,7625	0,2452	0,5100	36,26	37963,4	5915,2	68158,3	3738,5	115775,4	3,146	6,911	0,444	2,262	0,2375
0,5450	0,7561	0,2504	0,5100	34,34	37910,6	5831,0	68650,4	3797,2	116189,1	3,122	6,862	0,439	2,232	0,2439
0,5468	0,7501	0,2541	0,5100	22,79	37569,7	5771,8	68995,3	4250,6	116587,4	3,106	6,794	0,435	2,210	0,2499
0,5518	0,7368	0,2688	0,5100	44,20	38220,8	5537,2	70391,4	3502,6	117652,0	3,040	6,765	0,419	2,125	0,2632
0,5553	0,7243	0,2767	0,5101	23,49	37624,6	5412,5	71142,5	4219,3	118398,9	3,005	6,619	0,411	2,081	0,2757
0,5592	0,7148	0,2877	0,5105	39,20	38116,4	5229,8	72222,8	3666,1	119235,1	2,958	6,602	0,399	2,018	0,2852
0,5603	0,7091	0,2915	0,5100	31,52	37820,5	5193,8	72528,2	3926,1	119468,7	2,939	6,539	0,396	2,000	0,2909

Kriterij $C$ (p.u.)	Kriterij $1-Q$ (p.u.)	$r_{kb}$	$r_{vz}$	$t_r$ (ur)	$S_{Ne}$ (€)	$S_{Na}$ (€)	$S_v$ (€)	$V$ (€)	$C$ (€)	SAIFI <sub>Ne</sub>	SAIDI <sub>Ne</sub> (ur)	SAIFI <sub>Na</sub>	SAIDI <sub>Na</sub> (ur)	$Q$ (p.u.)
0,5635	0,7088	0,2901	0,5103	17,84	37495,0	5199,5	72436,2	5016,4	120147,0	2,947	6,507	0,396	2,005	0,2912
0,5664	0,6946	0,3032	0,5106	22,35	37615,7	4998,7	73696,0	4442,9	120753,3	2,891	6,414	0,383	1,934	0,3054
0,5672	0,6890	0,3099	0,5102	32,91	37818,9	4920,2	74285,4	3897,5	120922,1	2,860	6,406	0,377	1,901	0,3110
0,5703	0,6797	0,3198	0,5101	40,78	37978,9	4782,6	75217,6	3613,0	121592,2	2,817	6,367	0,368	1,849	0,3203
0,5716	0,6756	0,3229	0,5101	37,28	37863,0	4739,7	75515,2	3744,9	121862,7	2,803	6,327	0,364	1,833	0,3244
0,5733	0,6698	0,3281	0,5100	36,85	37802,2	4673,7	75992,0	3763,1	122231,0	2,780	6,286	0,360	1,808	0,3302
0,5752	0,6639	0,3327	0,5100	32,30	37648,9	4611,1	76430,1	3942,3	122632,5	2,760	6,231	0,355	1,784	0,3361
0,5797	0,6502	0,3455	0,5100	32,35	37551,6	4441,6	77642,1	3953,6	123588,9	2,705	6,134	0,343	1,721	0,3498
0,5822	0,6434	0,3549	0,5104	47,10	37904,1	4306,6	78565,1	3353,8	124129,6	2,667	6,136	0,334	1,673	0,3566
0,5877	0,6247	0,3726	0,5100	47,06	37664,4	4100,3	80204,0	3341,7	125310,4	2,590	6,004	0,319	1,592	0,3753
0,5897	0,6203	0,3731	0,5102	27,96	37193,8	4086,1	80270,6	4174,7	125725,2	2,589	5,907	0,318	1,588	0,3797
0,5910	0,6144	0,3821	0,5100	44,67	37489,0	3986,7	81097,0	3441,6	126014,3	2,550	5,923	0,310	1,548	0,3856
0,5918	0,6128	0,3840	0,5102	45,75	37524,3	3954,2	81307,6	3393,7	126179,8	2,543	5,916	0,308	1,538	0,3872
0,5933	0,6072	0,3896	0,5100	47,06	37452,8	3897,7	81811,5	3330,0	126492,0	2,518	5,880	0,304	1,514	0,3928
0,5970	0,5960	0,3994	0,5100	41,60	37176,3	3784,9	82738,3	3577,9	127277,4	2,477	5,780	0,295	1,471	0,4040
0,5978	0,5931	0,4039	0,5101	48,00	37284,1	3733,0	83161,1	3276,2	127454,3	2,460	5,783	0,291	1,451	0,4069
0,5994	0,5882	0,4080	0,5100	45,08	37141,3	3688,2	83547,8	3411,9	127789,3	2,442	5,737	0,288	1,434	0,4118
0,6005	0,5844	0,4125	0,5100	48,00	37145,6	3639,5	83968,3	3269,1	128022,5	2,424	5,721	0,284	1,415	0,4156
0,6028	0,5814	0,4107	0,5106	26,50	36698,4	3635,0	83875,1	4305,1	128513,6	2,435	5,617	0,285	1,419	0,4186
0,6045	0,5735	0,4194	0,5101	31,50	36620,6	3559,4	84641,0	4071,9	128892,9	2,396	5,578	0,278	1,385	0,4265
0,6100	0,5563	0,4355	0,5100	27,09	36212,0	3394,3	86142,1	4313,5	130062,0	2,329	5,432	0,266	1,319	0,4437
0,6115	0,5501	0,4476	0,5103	48,00	36562,4	3261,9	87318,7	3242,4	130385,4	2,282	5,472	0,256	1,270	0,4499
0,6142	0,5426	0,4505	0,5100	31,50	36042,6	3240,1	87572,5	4106,6	130961,9	2,269	5,347	0,254	1,259	0,4574
0,6180	0,5284	0,4696	0,5100	46,83	36045,7	3056,8	89375,3	3287,7	131765,5	2,191	5,307	0,239	1,187	0,4716
0,6198	0,5248	0,4686	0,5100	30,54	35631,6	3066,8	89274,7	4179,4	132152,5	2,196	5,206	0,240	1,191	0,4752

Kriterij C (p.u.)	Kriterij 1-Q(p.u.)	$r_{kb}$	$r_{vz}$	$t_r$ (ur)	$S_{Ne}$ (€)	$S_{Na}$ (€)	$S_v$ (€)	$V$ (€)	$C$ (€)	SAIFI <sub>Ne</sub>	SAIDI <sub>Ne</sub> (ur)	SAIFI <sub>Na</sub>	SAIDI <sub>Na</sub> (ur)	$Q$ (p.u.)
0,6214	0,5187	0,4779	0,5101	40,14	35690,1	2977,6	90165,0	3655,6	132488,3	2,159	5,203	0,233	1,156	0,4813
0,6271	0,5019	0,4926	0,5101	30,56	35082,2	2843,9	91560,0	4208,9	133695,0	2,101	5,029	0,223	1,103	0,4981
0,6276	0,4992	0,4967	0,5100	34,25	35072,7	2811,4	91931,4	3999,4	133814,9	2,085	5,025	0,220	1,089	0,5008
0,6294	0,4957	0,4995	0,5105	30,75	34951,6	2773,1	92257,0	4208,4	134190,0	2,077	4,981	0,217	1,078	0,5043
0,6307	0,4879	0,5118	0,5100	42,64	34918,9	2682,7	93361,0	3510,0	134472,6	2,025	4,980	0,209	1,037	0,5121
0,6335	0,4815	0,5118	0,5100	23,93	34384,0	2682,5	93362,6	4640,5	135069,6	2,025	4,834	0,209	1,037	0,5185
0,6345	0,4749	0,5283	0,5101	48,00	34635,4	2546,8	94925,5	3177,2	135284,9	1,962	4,908	0,198	0,983	0,5251
0,6381	0,4642	0,5406	0,5103	48,00	34314,4	2443,3	96125,7	3168,6	136052,0	1,916	4,825	0,190	0,944	0,5358
0,6389	0,4601	0,5449	0,5100	48,00	34153,8	2419,5	96488,2	3163,7	136225,2	1,898	4,794	0,188	0,931	0,5399
0,6412	0,4527	0,5534	0,5100	48,00	33900,2	2356,1	97289,8	3157,0	136703,1	1,865	4,737	0,182	0,906	0,5473
0,6438	0,4440	0,5634	0,5100	48,00	33588,7	2282,8	98243,3	3149,0	137263,9	1,827	4,668	0,176	0,876	0,5560
0,6455	0,4385	0,5688	0,5100	45,75	33347,9	2245,0	98746,9	3294,1	137633,8	1,807	4,611	0,173	0,860	0,5615
0,6460	0,4369	0,5703	0,5100	45,24	33280,6	2233,9	98896,0	3327,2	137737,8	1,801	4,595	0,172	0,856	0,5631
0,6484	0,4304	0,5797	0,5104	48,00	33102,1	2159,8	99840,5	3137,8	138240,2	1,769	4,560	0,167	0,829	0,5696
0,6488	0,4281	0,5785	0,5100	41,03	32874,4	2177,3	99669,8	3607,7	138329,2	1,770	4,498	0,167	0,833	0,5719
0,6509	0,4221	0,5818	0,5100	33,75	32525,9	2153,8	99989,5	4102,8	138771,9	1,758	4,403	0,166	0,824	0,5779
0,6514	0,4194	0,5926	0,5102	48,00	32650,0	2078,6	101030,1	3126,7	138885,4	1,719	4,473	0,160	0,794	0,5806
0,6537	0,4130	0,5949	0,5103	38,05	32235,4	2061,6	101263,7	3816,5	139377,3	1,711	4,355	0,158	0,788	0,5870
0,6585	0,3964	0,6209	0,5105	48,00	31653,7	1897,8	103741,2	3105,3	140398,0	1,617	4,287	0,144	0,722	0,6036
0,6619	0,3833	0,6367	0,5101	48,00	31018,9	1811,8	105192,7	3091,2	141114,6	1,557	4,181	0,137	0,685	0,6167
0,6636	0,3773	0,6423	0,5101	45,02	30684,5	1780,6	105719,4	3310,6	141495,1	1,537	4,108	0,134	0,672	0,6227
0,6661	0,3692	0,6548	0,5103	48,00	30311,3	1709,8	106928,6	3077,6	142027,3	1,494	4,064	0,128	0,644	0,6308
0,6680	0,3617	0,6640	0,5101	47,59	29895,2	1665,1	107760,7	3101,2	142422,2	1,459	3,997	0,124	0,624	0,6383
0,6698	0,3562	0,6717	0,5103	48,00	29602,3	1623,2	108516,9	3064,0	142806,3	1,433	3,954	0,120	0,609	0,6438
0,6699	0,3546	0,6734	0,5100	48,00	29508,0	1618,1	108638,0	3061,5	142825,6	1,426	3,942	0,120	0,605	0,6454

Kriterij $C$ (p.u.)	Kriterij $1-Q$ (p.u.)	$r_{kb}$	$r_{vz}$	$t_r$ (ur)	$S_{Ne}$ (€)	$S_{Na}$ (€)	$S_v$ (€)	$V$ (€)	$C$ (€)	$SAIFI_{Ne}$	$SAIDI_{Ne}$ (ur)	$SAIFI_{Na}$	$SAIDI_{Na}$ (ur)	$Q$ (p.u.)
0,6731	0,3437	0,6758	0,5101	33,11	28781,3	1604,1	108889,6	4235,1	143510,1	1,418	3,723	0,119	0,600	0,6563
0,6736	0,3425	0,6819	0,5103	38,63	28757,1	1572,7	109481,7	3802,3	143613,9	1,398	3,758	0,116	0,588	0,6575
0,6756	0,3350	0,6997	0,5102	48,00	28362,0	1489,1	111162,4	3041,6	144055,1	1,335	3,774	0,109	0,555	0,6650
0,6782	0,3242	0,7050	0,5100	38,20	27653,6	1467,3	111627,8	3843,4	144592,0	1,316	3,592	0,107	0,545	0,6758
0,6810	0,3141	0,7248	0,5100	44,76	27011,0	1380,6	113503,9	3294,6	145190,2	1,247	3,562	0,100	0,511	0,6859
0,6823	0,3093	0,7349	0,5100	48,00	26677,2	1339,0	114452,6	3012,6	145481,4	1,213	3,550	0,096	0,495	0,6907
0,6836	0,3025	0,7230	0,5100	26,79	26225,9	1388,6	113326,3	4811,9	145752,7	1,254	3,288	0,100	0,514	0,6975
0,6860	0,2947	0,7497	0,5100	42,84	25666,7	1280,0	115855,3	3452,0	146254,0	1,163	3,368	0,091	0,472	0,7053
0,6891	0,2808	0,7592	0,5100	34,13	24698,6	1243,7	116754,8	4222,6	146919,6	1,131	3,151	0,088	0,459	0,7192
0,6892	0,2798	0,7524	0,5100	26,36	24657,2	1269,5	116114,8	4899,6	146941,1	1,154	3,063	0,090	0,468	0,7202
0,6923	0,2683	0,7818	0,5100	38,24	23692,7	1162,4	118884,6	3866,4	147606,0	1,057	3,072	0,082	0,429	0,7317
0,6930	0,2644	0,7799	0,5101	32,29	23458,0	1168,6	118721,4	4407,2	147755,3	1,063	2,972	0,082	0,431	0,7356
0,6948	0,2560	0,7907	0,5100	31,54	22791,9	1131,7	119734,1	4487,4	148145,1	1,028	2,881	0,080	0,418	0,7440
0,6959	0,2524	0,7996	0,5101	34,34	22449,7	1102,3	120582,3	4236,3	148370,5	0,999	2,875	0,078	0,408	0,7476
0,6971	0,2465	0,8077	0,5100	34,13	21955,0	1076,2	121338,5	4262,5	148632,1	0,973	2,814	0,076	0,399	0,7535
0,6990	0,2441	0,8328	0,5102	48,00	21366,7	999,7	123736,8	2935,3	149038,5	0,893	2,948	0,070	0,375	0,7559
0,7000	0,2344	0,8122	0,5106	24,09	21087,0	1061,7	121866,2	5222,5	149237,4	0,962	2,576	0,075	0,396	0,7656
0,7018	0,2313	0,8481	0,5103	44,89	20236,9	956,5	125196,6	3231,5	149621,6	0,846	2,786	0,068	0,363	0,7687
0,7035	0,2137	0,8433	0,5100	25,82	19206,4	969,4	124702,1	5109,8	149987,7	0,860	2,381	0,069	0,366	0,7863
0,7060	0,2041	0,8675	0,5102	31,79	18055,0	904,1	127018,3	4550,0	150527,5	0,785	2,348	0,065	0,348	0,7959
0,7067	0,1988	0,8728	0,5101	30,28	17583,9	889,9	127497,7	4708,5	150680,1	0,769	2,273	0,064	0,345	0,8012
0,7103	0,1851	0,9152	0,5100	40,30	15469,2	786,4	131498,6	3691,5	151445,6	0,640	2,250	0,060	0,324	0,8149
0,7105	0,1789	0,9088	0,5100	32,77	15292,8	801,3	130893,8	4490,1	151478,0	0,659	2,086	0,061	0,326	0,8211
0,7115	0,1703	0,9045	0,5101	23,79	14870,4	812,0	130513,0	5499,7	151695,1	0,673	1,874	0,061	0,328	0,8297
0,7132	0,1653	0,9107	0,5101	23,10	14365,6	797,5	131098,4	5809,6	152071,1	0,654	1,805	0,061	0,326	0,8347

Kriterij $C$ (p.u.)	Kriterij $1-Q$ (p.u.)	$r_{kb}$	$r_{vz}$	$t_r$ (ur)	$S_{Ne}$ (€)	$S_{Na}$ (€)	$S_v$ (€)	$V$ (€)	$C$ (€)	SAIFI <sub>Ne</sub>	SAIDI <sub>Ne</sub> (ur)	SAIFI <sub>Na</sub>	SAIDI <sub>Na</sub> (ur)	$Q$ (p.u.)
0,7142	0,1538	0,9385	0,5103	27,61	12694,9	735,9	133759,7	5087,2	152277,8	0,573	1,732	0,059	0,317	0,8462
0,7149	0,1501	0,9547	0,5100	31,96	11855,9	699,5	135235,3	4625,6	152416,3	0,525	1,747	0,059	0,314	0,8499
0,7155	0,1418	0,9553	0,5101	26,45	11302,3	698,6	135299,8	5240,8	152541,5	0,523	1,575	0,059	0,314	0,8582
0,7177	0,1394	1,0000	0,5101	40,66	9212,2	607,8	139541,5	3659,3	153020,8	0,397	1,732	0,060	0,314	0,8606
0,7180	0,1281	1,0000	0,5100	34,18	8534,8	607,3	139523,0	4415,2	153080,3	0,397	1,512	0,060	0,314	0,8719
0,7181	0,1235	1,0000	0,5100	31,46	8250,6	607,2	139517,5	4732,7	153107,9	0,396	1,419	0,060	0,314	0,8765
0,7184	0,1164	1,0000	0,5101	27,24	7812,0	607,6	139533,7	5225,8	153179,0	0,397	1,276	0,060	0,314	0,8836
0,7245	0,1062	1,0000	0,5100	20,53	7121,6	607,2	139517,5	7224,7	154471,0	0,396	1,059	0,060	0,314	0,8938
0,7255	0,1053	1,0000	0,5100	19,94	7062,5	607,2	139518,2	7497,9	154685,7	0,396	1,041	0,060	0,314	0,8947
0,7305	0,1013	1,0000	0,5100	17,01	6765,3	607,2	139517,5	8868,8	155758,8	0,396	0,951	0,060	0,314	0,8987
0,7324	0,0998	1,0000	0,5100	15,95	6657,9	607,2	139517,5	9364,5	156147,0	0,396	0,918	0,060	0,314	0,9002
0,7385	0,0951	1,0000	0,5100	12,35	6294,5	607,2	139517,5	11041,4	157460,6	0,396	0,808	0,060	0,314	0,9049
0,7391	0,0946	1,0000	0,5100	12,00	6258,7	607,2	139517,5	11206,6	157590,0	0,396	0,797	0,060	0,314	0,9054



# ŽIVLJENJEPIS



## OSEBNI PODATKI

Ime in priimek: **Adnan GLOTIĆ**  
Naslov: Cesta Františka Foita 10, 3320 Velenje  
Telefon: 041/368-727  
Elektronska pošta: adnan.glotic@gmail.com  
Datum in kraj rojstva: 25. 11. 1980, Slovenj Gradec  
Državljanstvo: slovensko

## IZOBRAZBA

Obdobje: 2004 – 2006  
Pridobljena izobrazba: VII.  
Pridobljeni naziv: Univerzitetni diplomirani inženir elektrotehnike; diplomiral pod mentorstvom red. prof. dr. Jožeta Pihlerja  
Izobraževalna ustanova: Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko  
Program in smer: Univerzitetni študijski program Elektrotehnika, smer Močnostna elektrotehnika

Obdobje: 1999 – 2004  
Pridobljena izobrazba: VI/2.  
Pridobljeni naziv: Diplomirani inženir elektrotehnike; diplomiral pod mentorstvom red. prof. dr. Jožeta Pihlerja  
Izobraževalna ustanova: Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko

Program in smer: Visokošolski študijski program Elektrotehnika, smer Močnostna elektrotehnika

Obdobje: 1995 - 1999

Pridobljena izobrazba: V.

Pridobljeni naziv: Elektrotehnik - energetik

Izobraževalna ustanova: Šolski center Velenje, Srednja elektro in računalniška šola

Program in smer: Elektrotehnika - energetika

### **ZAPOSILITEV**

Obdobje: 2006 - 2011

Ime in naslov delodajalca: Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova ulica 17, 2000 Maribor

Delovno mesto: Mladi raziskovalec

Vrsta dejavnosti ali sektor: Izobraževanje in znanstveno-raziskovalna dejavnost

Skupne delovne izkušnje: 4,5 let





Univerza v Mariboru

Fakulteta za elektrotehniko,  
računalništvo in informatiko

## IZJAVA DOKTORSKEGA KANDIDATA

Podpisani-a Adnan GLOTIČ,  
vpisna številka 95031427

**izjavljam,**

da je doktorska disertacija z naslovom Optimiziranje elementov  
elektroenergetskega omrežja z uporabo evolucijskih algoritmov

- rezultat lastnega raziskovalnega dela,
- da predložena disertacija v celoti ali v delih ni bila predložena za pridobitev kakršnekoli izobrazbe po študijskem programu druge fakultete ali univerze,
- da so rezultati korektno navedeni in
- da nisem kršil-a avtorskih pravic in intelektualne lastnine drugih.

Podpis doktorskega-e kandidata-ke:



Univerza v Mariboru

Fakulteta za elektrotehniko,  
računalništvo in informatiko

### IZJAVA KANDIDATOVEGA MENTORJA O USTREZNOSTI DOKTORSKE DISERTACIJE

Podpisani-a JOŽE PIHLER, mentor-ica doktorskemu-i  
kandidatu-ki, izjavljam, da je doktorska disertacija z naslovom

Optimiranje elementov elektroenergetskega  
omrežja z uporabo evlucijskih  
algoritmov

ki jo je izdelal-a doktorski-a kandidat-ka ADNAN GLORIČ  
v skladu z odobreno temo, Pravilnikom o pripravi in zagovoru doktorske disertacije ter  
mojimi navodili in predstavlja izviren prispevek k razvoju znanstvene discipline.

Datum in kraj:

Maribor, 22.4.2011

Podpis mentorja-ice:

J. Pihler



Univerza v Mariboru

Fakulteta za elektrotehniko,  
računalništvo in informatiko

## IZJAVA O OBJAVI ELEKTRONSKE VERZIJE DOKTORSKE DISERTACIJE IN OSEBNIH PODATKOV, VEZANIH NA ZAKLJUČEK ŠTUDJA

Ime in priimek doktoranda-ke: Admon GLOTIČ  
Vpisna številka: 95031427  
Študijski program: Doktorski študijski program Elektrotehnika  
Naslov doktorskega dela:  
Optimiziranje elementov elektroenergetskega omrežja z uporabo  
evolucijskih algoritmov

Mentor-ica: red. prof. dr. Jože PIHLER  
Somentor-ica: red. prof. dr. Igor TIČAR

Podpisani soglašam z objavo doktorske disertacije v Digitalni knjižnici Univerze v Mariboru.

Tiskana verzija doktorske disertacije je istovetna elektronski verziji, ki sem jo oddal-a v Digitalno knjižnico Univerze v Mariboru.

Podpisani-a hkrati izjavljam, da dovoljujem objavo osebnih podatkov, vezanih na zaključek študija (ime, priimek, leto in kraj rojstva, datum diplomiranja, naslov diplomskega dela) na spletnih straneh in v publikacijah Univerze v Mariboru.

Datum in kraj:

Maribor, 22.4.2011

Podpis doktoranda-ke:

