Određivanje i detekcija viših harmonika evolucijskim algoritmom

Vlahović-Babić, Josip

Master's thesis / Diplomski rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:097054

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ELEKTROTEHNIČKI FAKULTET

Sveučilišni diplomski studij

ODREĐIVANJE I DETEKCIJA VIŠIH HARMONIKA EVOLUCIJSKIM ALGORITMOM

Diplomski rad

Josip Vlahović Babić

Osijek, 2015. Godina

Sadržaj

1. UVOD 1
2. UVOD U VIŠE HARMONIKE 2
   2.1. Uzroci pojava viših harmonika 4
   2.2. Zasićenja fizikalnog svojstva otpornosti 6
   2.3. Zasićenja fizikalnog svojstva kapacitivnosti 7
   2.4. Zasićenja fizikalnog svojstva induktivnosti 8
   2.5. Uzroci i posljedice viših harmonika 9
   2.6. Prikaz valnih oblika u frekvencijskoj domeni 10
3. PRIRODNA EVOLUCIJA 13
   3.1. Kromosomi i molekula DNK 13
   3.2. Vrste evolucijskih algoritama 15
   3.3. Funkcija dobrote 16
   3.4. Selekcija 17
   3.5. Križanje 18
   3.6. Mutacija 19
   3.7. Algoritmi zasnovani na evoluciji 20
4. OPIS ALATA ZA SIMULACIJU 21
   4.1. Populacija 22
   4.2. Skaliranje funkcije cilja 23
   4.3. Selekcija 24
   4.4. Reprodukcija 25
   4.5. Mutacija 25
   4.6. Križanje 25
   4.7. Migracija 26
   4.8. Ostale postavke algoritma 27
   4.9. Hibridna funkcija 27
5. RAZRADA I DEFINIRANJE OPTIMIZACIJSKOG PROBLEMA ZA ODREĐIVANJE I DETEKCIJU VIŠIH HARMONIKA 30
   5.1. Kreiranje funkcije cilja u Matlab-u 32
   5.2. Kreiranje m skripte za pokretanje GA 32
   5.3. Primjer pisanja koda za pokretanje GA 33
   5.4. Primjer pisanja koda za izračun funkcije cilja 35
6. OBAVLJANJE SIMULACIJE 36

6.1. Testiranje rada genetskog algoritma 36
6.2. Utjecaj promjene parametara na rad GA 41
6.3. Zapis signala kao zbroj sinusa i kosinusa 43
6.4. Određivanje frekvencije osnovnog harmonika pomoću GA 45
6.5. Utjecaj šuma na rad genetskog algoritma 49
6.6. Sposobnost GA kod detekcije harmonika 53
6.7. Utjecaj promjene amplitude harmonika 55
6.8. Utjecaj skokovite promijene amplituda harmonika 58
6.9. Određivanje svih frekvencija harmonika u signalu 60
6.10. Određivanje samo viših harmonika u signalu 62
6.11. Utjecaj određivanja istih harmonika 65
6.12. Određivanje viših harmonika (amplitude i faze) 69
6.13. Uzastopno ponavljanje GA radi dobivanja boljih rezultata 74
7. ZAKLJUČAK 76
8. LITERATURA 77

SAŽETAK

Kako bi se što bolje uklonile ili ublažile posljedice viših harmonika u sinosuidalnom valnom obliku napona, na električnu opremu i uređaje potrebna je pravilna detekcija i određivanje viših harmonika. Jedan način, na kojem se ovaj rad zasniva, je korištenje genetskog algoritma. Kroz simulacije u programskom paketu Matlab, dobivaju se zadovoljavajući rezultati. Simulirani su utjecaji promjenjive ili konstantne istosmjerne komponente, opisiva ili skokovita promjena amplituda harmonika, utjecaj međuharmonika te šuma u signalu. Rastavljanje ukupnog problema na dva manja problema te pokretanje dva genetska algoritma, po jedan za svaki problem, se pokazalo puno uspješnije nego rješavanje cijelog problema jednim genetskim algoritmom. Najbolji rezultati za ovakav problem pokazali su parametri: turnirska selekcija, adaptivno izvediva mutacija te raspršeno križanje. Harmonijska analiza genetskim algoritmom se isplati koristiti kada se radi o kompliciranim signalima jer je genetski algoritam moguće prilagoditi raznim problemima.

Ključne riječi:

Viši harmonici, genetski algoritam, evolucija, funkcija cilja, nelinearna opterećenja, ukupno harmonijsko izobličenje, operatori genetskog algoritma, frekvencijski spektar, jedinka, broj generacija, dobrota jedinke, strujno-naponska izobličenja, nesinusoidalni oblici, Matlab-ov optimizacijski alat,…

SUMMARAY

In order to eliminate or mitigate the consequences of higher harmonics on the electrical equipment and appliances it is important to conduct proper detection and determination of the higher harmonics in the sinusoidal wave form. This work is based on one particular way of doing this, using genetic algorithm. Satisfactory results where obtained through simulation in Matlab software package. The effects of a variable or a constant DC component, mathematically describable or step changes of the amplitude of harmonics, inter-harmonics and the impact of noise in the signal where simulated. Dismantling oft he overall problem into two smaller problems, and running two genetic algorithms, one for each problem, turned out a lot more successful than solving the whole problem with one genetic algorithm. The best results for this kind of problems where obtained using the following parameters: tournament selection, adaptive feasible mutation and scattered crossover. It is worthwhile using genetic algorithm when dealing with complicated signals because the genetic algorithm can be adopted to suit various problems.

Key words:

Higher harmonics, genetic algorithm, evolution, fitness function, non-linear loads, total harmonic distortion, genetic algorithm operators, frequency spectre, individual, number of generations, score of the individual, current and voltage distortions, non-sinusoidal shapes, Matlab optimisation toolbox,…