

MULTIKRITERIJSKA OPTIMIZACIJA PUTANJE ČETVEROPOLUŽNOG MEHANIZMA ZASNOVANA NA GENETIČKIM ALGORITMIMA

MULTIPLE-CRITERIA OPTIMIZATION OF A FOURBAR MECHANISM TRAJECTORY BASED ON GENETIC ALGORITHMS

Miroslav Maretić, Zoran Vrhovski, Dalibor Purković

Pregledni članak

Sažetak: U radu je opisana optimizacija skalarnih matematičkih funkcija i multikriterijska optimizacija putanje četveropolužnog mehanizma zasnovana na genetičkim algoritmima. Genetičkim se algoritmom optimiziraju parametri Hoekenovog četveropolužnog mehanizma koji na jednom dijelu putanje aproksimira pravocrtno gibanje. Problem optimizacije parametara četvoropolužnog mehanizma promatra se kao dvokriterijski jer je potrebno zadovoljiti položaj krajnje točke mehanizma po x-osi i po y-osi. Algoritam realiziran u JavaScript programskom jeziku optimizira parametre Hoekenovog mehanizma koji su sintetizirani u programskom alatu SAM 6.0.

Ključne riječi: genetički algoritmi, multikriterijska optimizacija, mutacija, putanja četveropolužnog mehanizma, rekombinacija, spremnost

Subject review

Abstract: The paper presents the optimization of scalar mathematical functions and the multiple-criteria optimization of a fourbar mechanism trajectory based on genetic algorithms. The genetic algorithm optimizes the parameters of the Hoeken fourbar mechanism which approximates rectilinear motion along a part of its trajectory. The optimization problem related to the fourbar mechanism parameters is observed as having two criteria due to the fact that it is necessary to simultaneously satisfy the position of the end point of the mechanism on both the x-axis and the y-axis. The algorithm, which is realized in the JavaScript programming language, optimizes the parameters of the Hoeken fourbar mechanism which are synthesized in the SAM 6.0 software tool.

Key words: genetic algorithms, multiple-criteria optimization, fourbar mechanism trajectory, mutation, recombination, fitness

1. UVOD

Genetički algoritmi su numerička metoda optimizacije temeljena na evoluciji organizama koja se susreće u biološkom svijetu. Pojavljuju se ranih 60-tih godina prošlog stoljeća te od tada napreduju u strukturi i primjeni [1]. Mnogim pojmovima koji su preuzeti iz biologije su u okviru genetičkih algoritama svršishodno prilagođena značenja. Evolucija se u prirodi, kao izričaj dinamike biološkog svijeta, promatra kroz okvir poboljšanja karakteristika organizma iz neke populacije s ciljem povećanja vjerojatnosti preživljavanja tog organizma i stvaranja potomaka. U genetičkim algoritmima analogno tome promatra se populacija rješenja koja je podvrgnuta simuliranim evolucijskim silama s ciljem pronalaženja rješenja funkcije cilja koje zadovoljava određene kriterije. Funkcija cilja je funkcija koju je potrebno minimizirati ili maksimizirati, odnosno optimizirati. Važnu ulogu u genetičkim algoritmima ima jedan atribut rješenja koji odražava kvalitetu rješenja u okviru danog problema, a koji se naziva sposobnost preživljavanja ili spremnost. U ovom će se radu koristiti naziv spremnost (engl. *fitness*).

Genetički će se algoritmi u ovom radu koristiti za optimizaciju putanje četveropolužnog mehanizma (engl. *fourbar mechanism*) [2]. Prednosti genetičkih algoritama naspram tradicionalnih analitičkih postupaka optimizacije (npr. gradijentnih Newtonovih metoda) je u tome što funkcija cilja koja se optimizira ne treba biti niti analitička niti derivabilna funkcija.

Rad je strukturiran na sljedeći način. U drugom poglavlju opisana je terminologija i način realizacije pojedinih komponenti genetičkih algoritama. Treće poglavlje opisuje način primjene genetičkih algoritama na primjeru određivanja numeričkog minimuma skalarnih matematičkih funkcija na nekom intervalu. Poglavlje četiri opisuje tematiku multikriterijske optimizacije koja predstavlja realne probleme s nizom istodobno promatranih spremnosti rješenja. Nakon toga je prikazana primjena multikriterijske optimizacije na primjeru optimizacije putanje četveropolužnog mehanizma te su prikazani dobiveni rezultati. U petom poglavlju dan je zaključak.

Algoritmi su realizirani u JavaScript [3] programskom jeziku u pozadini HTML stranice koja predstavlja sučelje. Za analizu i sintezu planarnih

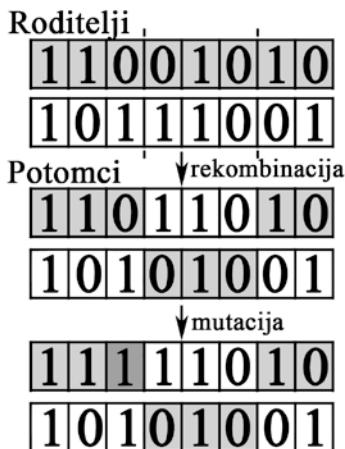
mehanizma korišten je programski alat SAM 6.0 [4] iz kojeg su preuzete slike dobivenih mehanizama.

2. GENETIČKI ALGORITMI

Rješenja su u ovom radu predstavljena binarnim nizom zbog pogodnosti takve notacije s obzirom na potrebu proračuna genetičkog algoritma. Postoje i drugačiji načini notacije rješenja u zavisnosti od tipa problema koji se rješava [1]. Primjer jednog rješenja je prikazan na slici 1.

Slika 1. Primjer rješenja

Bitovi niza su strukturalni elementi rješenja na razini gdje djeluju evolucijski operatori. Postoje dva važna evolucijska operatora, mutacija i rekombinacija [5]. Rekombinacija djeluje na način da rekombinira postojeće informacije u populaciji tvoreći tako rješenja koja ne sadrže intrisično nove informacije. Mutacija djeluje na pojedinim bitovima rješenja mijenjajući ih i tvoreći tako potencijalno nove informacije u populaciji. Oba operatora djeluju s određenim vjerojatnostima čije se vrijednosti ponajbolje određuju eksperimentalno za pojedine tipove problema. Primjer rekombinacije dva rješenja na dvije točke niza te mutacije prvog kreiranog rješenja na trećem bitu je prikazan na slici 2.



Slika 2. Primjer rekombinacije i mutacije

Kao kriterij na osnovu kojeg se odabiru rješenja pomoću kojih se kreiraju naredne generacije populacije, koristit će se spremnost. Spremnost je realan broj koji u sebi objedinjuje karakteristike rješenja na osnovu kojih se određuje kvaliteta tog rješenja. Rješenje koje je prema nekom kriteriju kvalitetnije ima veću spremnost i obratno. Općenito se način određivanja spremnosti bazira na tipu problema koji se rješava. Često je potrebno i poželjno dodatno skalirati spremnost rješenja s obzirom na ostatak populacije kako bi se dobio ravnomjerniji selekcijski pritisak [1], [5], [6].

Tijekom procesa mutacije i odabira rješenja za rekombinaciju može se dogoditi da mutiraju informacije najspretnijeg člana trenutne generacije ili da se on uopće ne odabere kao roditelj. Naredna generacija ne mora

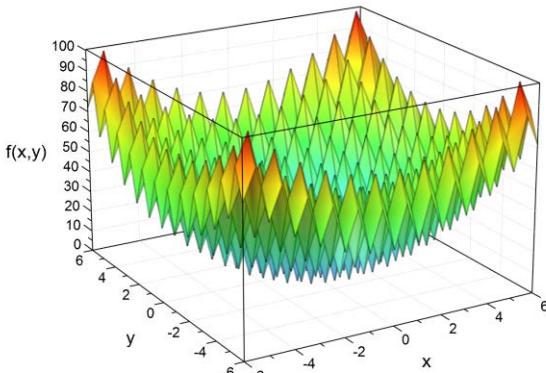
nužno imati rješenje koje je spremnije od najspretnijeg člana prethodne generacije. Da bi se takvi gubici potencijalno korisnih informacija izbjegli, vrši se prije uvođenja naredne generacije elitistička provjera [1]. Nakon što se formira naredna generacija, provjerava se da li prethodna generacija ima član koji ima veću spremnost od najspretnijeg člana naredne generacije. Ako je tako, nasumično se jedan član naredne generacije zamjeni tim članom prethodne generacije.

3. OPTIMIZACIJA SKALARNIH MATEMATIČKIH FUNKCIJA

Kao jedan od primjera upotrebe genetičkih algoritama prikazuje se pronalaženje numeričkog minimuma skalarnih matematičkih funkcija na nekom intervalu. Obično se genetički algoritmi koncipiraju tako da se definira funkcija cilja koju je potrebno optimizirati, a s kojom je povezana spremnost na način da rješenja imaju veću spremnost što bolje optimiziraju funkciju cilja. Evaluacija funkcije cilja za pojedina rješenja obično zauzima najviše računalnog vremena kao resursa te je stoga potrebno posvetiti pažnju učinkovitosti tog dijela kôda [7]. Svako rješenje je potrebno dekodirati iz binarnog oblika u realni broj na osnovu kojeg se može odrediti vrijednost funkcije cilja.

Kao testna funkcija cilja koristit će se Rastriginova funkcija (1) koja je vrlo pogodna za testiranje genetičkog algoritma na čisto numeričkom problemu. Dvodimenzionalna funkcija prikazana je na slici 3.

$$f(x, y) = 20 + x^2 + y^2 - 10 \cos(2\pi x) - 10 \cos(2\pi y) \quad (1)$$



Slika 3. Rastriginova funkcija

Funkciju cilja koju će algoritam minimizirati je vrijednost funkcije (1) na intervalu $x \in [-6, 6]$, $y \in [-6, 6]$. Na danom će se intervalu tražiti minimum funkcije. Rastriginova funkcija, kao što se vidi na slici 3, ima niz lokalnih minimuma te bi pronalaženje globalnog minimuma bio problem s tradicionalnim gradijentnim metodama minimizacije. Gradijentne metode minimizacije "zaglavile" bi u nekom od lokalnih minimuma jer rješenje ovisi isključivo o početnim uvjetima.

Spremnost pojedinog rješenja s određuje se na osnovu izraza (2). Iz grafa se funkcije vidi da je minimum

funkcije (1) u točki $f(0,0) = 0$ te bi spremnost u danoj točki bila $s = 1/0 = \infty$.

$$s = \frac{1}{|f(x,y)|} \quad (2)$$

Ukoliko se pretpostavi bitovni niz 10100101, prva četiri bita predstavljaju varijablu x , a naredna četiri bita predstavljaju varijablu y . Tako su dobiveni ekvivalentni cijeli brojevi $z_x(1010) = 10$ i $z_y(0101) = 5$ koji se prema izrazu (3) [7] preslikavaju u intervale $x \in [-6, 6]$, $y \in [-6, 6]$ u kojem se promatraju rješenja.

$$r_i = \frac{r_{\max} - r_{\min}}{2^l - 1} z_i + r_{\min}, \quad i = x, y \quad (3)$$

Varijable r_{\max} i r_{\min} predstavljaju granice intervala (u ovom slučaju $r_{\max} = 6$, $r_{\min} = -6$), a varijabla l predstavlja duljinu bitovnog niza pojedine varijable (u ovom slučaju $l = 4$). Prema izrazu (3) dobivene su vrijednosti $r_x = 2$ i $r_y = -2$. Za dobivene vrijednosti r_x i r_y , vrijednost funkcije cilja je $f(r_x, r_y) = f(2, -2) = 8$, a vrijednost spremnosti je $s = \frac{1}{8} = 0.125$.

Kao što je napomenuto, dobivenu sirovu spremnost potrebno je skalirati kako bi se uravnotežio selekcijski pritisak prilikom odabira roditelja s ciljem izbjegavanja konvergiranja rješenja u neki od lokalnih minimuma. U ovom slučaju će se koristiti sigma skaliranje spremnosti prema izrazu [6]:

$$s_e = 1 + \frac{s_i + S_{avg}}{2\sigma} \quad (4)$$

gdje je s_i sirova spremnost dobivena izrazom (2), S_{avg} srednja spremnost populacije, a σ standardna devijacija sirove spremnosti. Srednja spremnost i standardna devijacija sirove spremnosti definirane su izrazima:

$$s_e = 1 + \frac{s_i + S_{avg}}{2\sigma} \quad (5a)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_i^n (s_i - S_{avg})^2} \quad (5b)$$

pri čemu je n broj članova populacije. Na osnovu skalirane spremnosti odabiru se parovi roditelja čiji se bitovni nizovi podvrgavaju rekombinaciji te mutaciji s ciljem dobivanja članova naredne generacije populacije. Jedna od tradicionalno popularnih metoda selekcije roditelja je proporcionalna selekcija u kojoj je vjerojatnost da će neko rješenje biti izabранo za roditelja proporcionalno njegovoj spremnosti. Implementacija proporcionalne selekcije definirana je sljedećim koracima:

1. Sumiraju se spremnosti svih članova populacije: $S_p = \sum_1^n s_e(i)$.
2. Nasumično se odabere broj iz intervala $[0, S_p]$.
3. Zbrajaju se spremnosti članova populacije redom (članovi ne smiju biti u strukturi populacije poredani po spremnosti) sve dok ta suma ne pređe odabrani

nasumični broj. Zadnji dodani član se tada odabire kao roditelj.

Rekombinacija i mutacija roditelja odvija se s određenom vjerojatnošću. Vjerojatnost rekombinacije koja se koristi u ovom radu je $v_{rec} = 0.95$, a vjerojatnost mutacije $v_{mut} = 0.02$. Nakon odabira dva roditelja, generira se nasumični broj u intervalu $rec_{nas} \in [0, 1]$. Ukoliko vrijedi $rec_{nas} > v_{rec}$ roditelji se ne rekombiniraju, već se samo prosljeđuju u narednu generaciju. Ako je $rec_{nas} \leq v_{rec}$ tada dolazi do rekombinacije roditelja. Nakon što se kreira kompletan naredna generacija populacije, prolazi se kroz sve bitove bitovnih nizova članova s ciljem mutacije. Prilikom razmatranja svakog bita generira se nasumično broj u intervalu $mut_{nas} \in [0, 1]$. Ukoliko vrijedi $mut_{nas} \leq v_{mut}$ odabrani bit mutira.

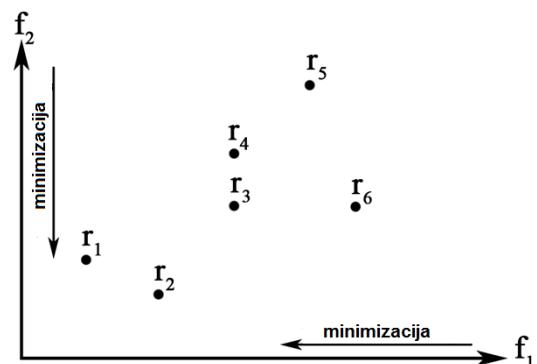
Nakon obrađene i kreirane naredne generacije vrši se elitistička provjera nakon koje novokreirana generacija postaje trenutna generacija populacije te se kompletan algoritam ponavlja do zadovoljenja određenog kriterija na funkciju cilja.

4. MULTIKRITERIJSKA OPTIMIZACIJA

Navedeni primjer optimizacije skalarne matematičke funkcije je primjer gdje je potrebno minimizirati samo jednu funkciju cilja koja predstavlja kvalitetu rješenja. Realni problemi često posjeduju niz parametara koji određuju krajnju kvalitetu rješenja na način da tvore nekoliko funkcija cilja koje je potrebno minimizirati. Parametri problema su najčešće spregnuti tako da nije moguće minimizirati jednu funkciju cilja bez da se promijeni vrijednost druge funkcije cilja.

Općenito vrijedi da se problem promatra tako da se kreira vektor parametara kojima se mijenja vrijednost. Taj vektor tvori niz funkcija cilja koje je potrebno minimizirati, $f_1(\vec{x}), f_2(\vec{x}), \dots, f_m(\vec{x})$. Svako rješenje (član populacije) je ciljni vektor koji sadrži funkcije cilja, $\vec{F} = \{f_1, f_2, \dots, f_m\}$. Pomoću Pareto dominacije [8] određuje se relativna kvaliteta između dva rješenja. Općenito, vektor \vec{F}_a dominira nad vektorom \vec{F}_b ako vrijedi:

$$\begin{aligned} f_{a,i} &\leq f_{b,i} \quad \forall i \in \{1, 2, \dots, m\} \wedge \\ &\wedge f_{a,j} \leq f_{b,j} \quad \exists j \in \{1, 2, \dots, m\} \end{aligned} \quad (6)$$



Slika 4. Primjer populacije rješenja dvokriterijskog problema

Dominacija vektora \vec{F}_a nad vektorom \vec{F}_b označavat će se s $\vec{F}_a < \vec{F}_b$. Primjena Pareto dominacije će biti prikazana na primjeru dvokriterijskog problema na slici 4 gdje su pojedina rješenja \vec{r}_i obilježena oznakama r_i .

Sa slike 4 određuje se dominacija rješenja kako slijedi:

1. $r_1 < \{r_3, r_4, r_5, r_6\}$
2. $r_2 < \{r_3, r_4, r_5, r_6\}$
3. $r_3 < \{r_4, r_5, r_6\}$
4. $r_4 < r_5$

Na osnovu broja dominirajućih rješenja svakom se rješenju dodjeljuje rang prema izrazu (7) gdje je q_i broj rješenja koja dominiraju nad odgovarajućim rješenjem i .

$$\text{rang}(i) = 1 + q_i \quad (7)$$

Na osnovi izraza (7) rješenja sa slike 4 imaju sljedeće rangove:

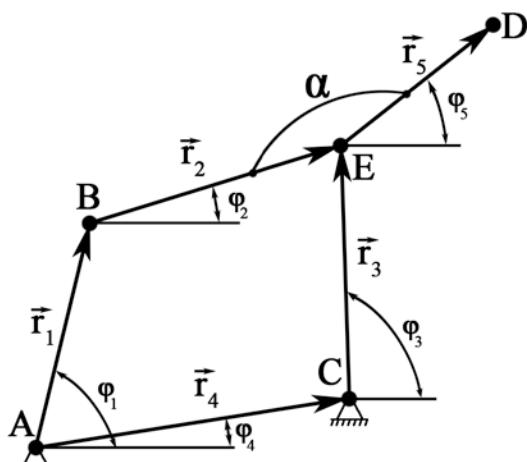
1. $\text{rang}(r_1) = 1$
2. $\text{rang}(r_2) = 1$
3. $\text{rang}(r_3) = 3$
4. $\text{rang}(r_4) = 4$
5. $\text{rang}(r_5) = 5$
6. $\text{rang}(r_6) = 4$

Iako postoje razne metode određivanja spretnosti [9] obrnuto proporcionalni odnos spretnosti i ranga (8) daje dobre rezultate.

$$s_i = \frac{1}{\text{rang}(r_i)} \quad (8)$$

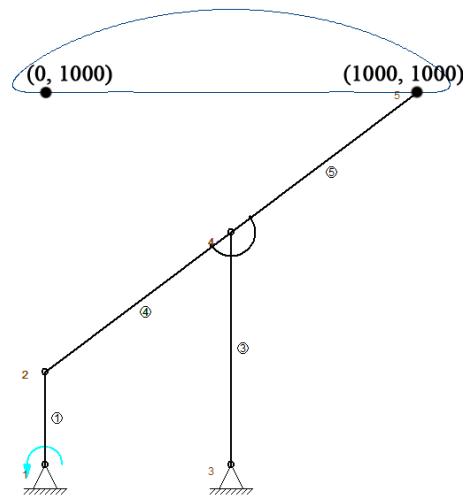
4.1. Multikriterijska optimizacija putanje četveropolužnog mehanizma

Kao primjer primjene multikriterijske optimizacije zasnovane na genetičkim algoritmima predlaže se optimizacija planarne putanje četveropolužnog mehanizma. Opći četveropolužni mehanizam prikazan je na slici 5, pri čemu su poluge označene vektorima zbog potrebe matematičke analize [6].



Slika 5. Opći izgled četveropolužnog mehanizma s naznačenim geometrijskim parametrima

Referentna putanja za generiranje parametara mehanizma i mehanizam koji ostvaruje putanje su prikazani na slici 6. Mehanizam je poznat pod nazivom Hoekenov mehanizam, i kao što se vidi, on aproksimira pravocrtno gibanje na jednom dijelu putanje. Dakle, cilj genetičkog algoritma je kreirati Hoekenov mehanizam optimizacijom putanje prikazane na slici 6. Problem optimizacije promatra se kao dvokriterijski jer je potrebno zadovoljiti položaj točke D po x-osi i po y-osi.



Slika 6. Hoekenov mehanizam s naznačenom putanjom i koordinatama

Hoekenov mehanizam sa slike 6 kreiran je tako da je smješten u nepomični referentni koordinatni sustav u kojem se promatraju sve potrebne geometrijske osobine mehanizma. Koordinata oslonca A smještena je u ishodište $(0, 0)$, a koordinata oslonca C u točku $(500, 0)$. Uz odabrane dužine poluga $|\vec{r}_2| = |\vec{r}_3| = |\vec{r}_5| = 625 \text{ mm}$, $|\vec{r}_1| = 250 \text{ mm}$ i $|\vec{r}_4| = 500 \text{ mm}$ te $\alpha = 180^\circ$ slijedi da dio putanje koji aproksimira pravac ima krajnje točke $(0, 1000)$ i $(1000, 1000)$. Dužine poluga definirane su odnosima poluga u Hoekenovom mehanizmu [2].

U algoritmu optimizacije se kao parametri koriste geometrijske osobine mehanizma. Prema slici 5. određuju se vrijednosti dužina poluga $|\vec{r}_1|, |\vec{r}_2|, |\vec{r}_3|, |\vec{r}_5|$, kuta α te koordinate oslonca C, (x_C, y_C) . Svako rješenje je predstavljeno bitovnim nizom duljine 70 bitova te svakom parametru pripada redom 10 bitova. Dužine poluga su ograničene na $|\vec{r}_i| \in [100, 1000]$. Koordinate oslonca ograničene su na $x_C, y_C \in [100, 1000]$. Vrijednost kuta ograničena je na $\alpha \in [100, 270]$. Početne vrijednosti parametara u nultoj generaciji generiraju se nasumično u zadanim granicama.

Za određivanje koordinate točke D koriste se izrazi:

$$x_D = |\vec{r}_1| \cos(\varphi_1) + |\vec{r}_2| \cos(\varphi_2) + |\vec{r}_5| \cos(\varphi_5) \quad (9a)$$

$$y_D = |\vec{r}_1| \sin(\varphi_1) + |\vec{r}_2| \sin(\varphi_2) + |\vec{r}_5| \sin(\varphi_5) \quad (9b)$$

Za svaki stupanj kuta $\varphi_1 \in [90, 270]$ i pogonske poluge $|\vec{r}_1|$ izračunati su položaji točke D Hoekenovog mehanizma te su pohranjeni u nizove \vec{X}_{Dh} i \vec{Y}_{Dh} . Svako

rješenje u algoritmu optimizacije se podvrgava istim proračunima te se određuju položaji točke D mehanizma koji se spremaju u nizove \vec{X}_{De} i \vec{Y}_{De} . Svakom mehanizmu je početni položaj definiran pomoću kuta $\varphi_1 = 90^\circ$. Funkcije cilja koje je potrebno minimizirati su u ovom slučaju srednje kvadratne pogreške putanje u promatranim točkama po x-osi i y-osi predstavljene izrazima:

$$MSE_x = \frac{1}{180} \sum_{i=1}^{180} [\vec{X}_{De}(i) - \vec{X}_{Dh}(i)]^2 \quad (10a)$$

$$MSE_y = \frac{1}{180} \sum_{i=1}^{180} [\vec{Y}_{De}(i) - \vec{Y}_{Dh}(i)]^2 \quad (10b)$$

Dvije spretnosti bazirane na ovim funkcijama cilja određuju se na osnovu izraza:

$$s_x = \frac{1}{MSE_x} \quad (11a)$$

$$s_y = \frac{1}{MSE_y} \quad (11b)$$

Prema već opisanom postupku svako rješenje rangira se na osnovi Pareto dominacije (6) (7), spretnost se određuje na osnovu dobivenog ranga (8) te se vrši proporcionalna selekcija nad tako dobivenom populacijom.

Kod nasumičnog kreiranja rješenja u nultoj generaciji te kreiranja rješenja u narednim generacijama na osnovu rekombinacije i mutacije moguće je kreirati mehanizam kojeg fizički nije moguće ostvariti ili koji ima ograničenu pokretljivost. Takvim se rješenjima spretnost postavlja na 10^{-10} , a srednje kvadratna pogreška na ∞ .

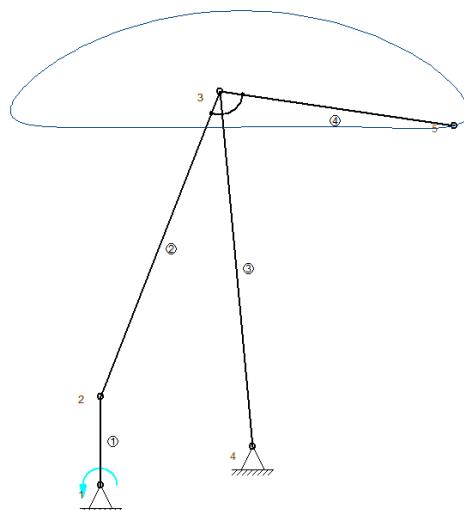
Elitistička provjera je izvedena tako da se iz trenutne generacije odabere rješenje koje ima najveću spretnost po osi y (11b) te se ono uspoređuje s rješenjem iz međupopulacije (nastale rekombinacijom i mutacijom trenutne generacije) koje ima najveću spretnost prema (11b). Zanemaruje se eksplicitna provjera spretnosti po osi x (11a) jer je oslonac A fiksno postavljen u ishodište koordinatnog sustava te je važnije imati manje oscilacije po osi y, nego po osi x. Zbog ograničenosti oslonca A i ograničenja duljine poluga neposredno se kod elitističke provjere prati i spretnost po osi x.

Ovaj algoritam optimizacije, iako implementira samo osnove genetičkih algoritama te ne upotrebljava složenije određivanje spretnosti multikriterijskih problema (pogledati [8] i [9]), daje rezultate koji ilustriraju uspešnost uporabe ove metode. Na slikama 7 i 8 su dani primjeri mehanizma i putanje koje opisuje točka D.

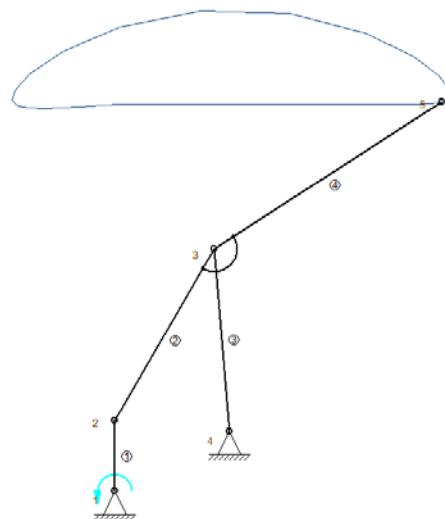
Mehanizam sa slike 7 ima vrijednosti geometrijskih parametara dobivenih multikriterijskom optimizacijom:

$$\begin{aligned} |\vec{r}_1| &= 247 \text{ mm} \\ |\vec{r}_2| &= 916 \text{ mm} \\ |\vec{r}_3| &= 996 \text{ mm} \\ |\vec{r}_5| &= 662 \text{ mm} \\ x_C &= 426 \text{ mm} \end{aligned}$$

$$\begin{aligned} y_C &= 108 \text{ mm} \\ \alpha &= 240^\circ \end{aligned}$$



Slika 7. Primjer dobivenog mehanizma multikriterijskom optimizacijom (1)

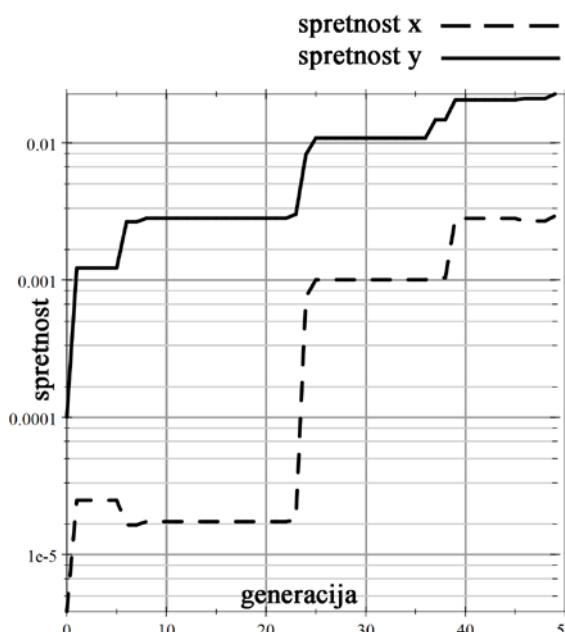


Slika 8. Primjer dobivenog mehanizma multikriterijskom optimizacijom (2)

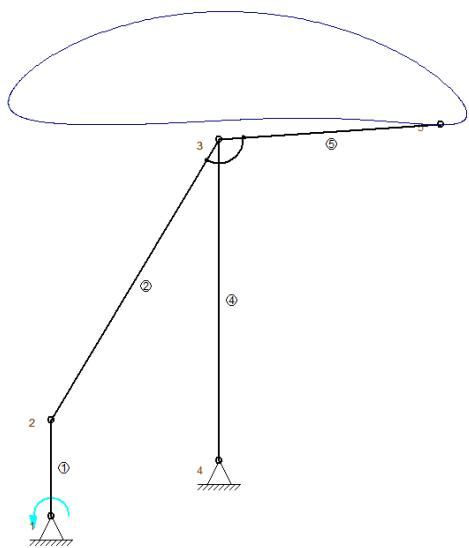
Mehanizma sa slike 8. ima vrijednosti geometrijskih parametara dobivenih multikriterijskom optimizacijom:

$$\begin{aligned} |\vec{r}_1| &= 183 \text{ mm} \\ |\vec{r}_2| &= 513 \text{ mm} \\ |\vec{r}_3| &= 473 \text{ mm} \\ |\vec{r}_5| &= 701 \text{ mm} \\ x_C &= 296 \text{ mm} \\ y_C &= 155 \text{ mm} \\ \alpha &= 207^\circ \end{aligned}$$

Na slici 9 je prikazana ovisnost maksimalne spretnosti s_x i s_y u prvih 50 generacija jedne populacije uz vrijednosti vjerojatnosti rekombinacije $v_{rec} = 0.95$ i vjerojatnosti mutacije $v_{mut} = 0.02$. Na slici 10 je prikazan dobiveni mehanizam nakon 50 generacija jedne populacije. Promjena spretnosti s_x prati promjenu spretnosti s_y iako se tijekom elitističke provjere eksplicitno ne provjerava.



Slika 9. Tok maksimalne spremnosti tijekom 50 generacija



Slika 10. Primjer dobivenog mehanizma na temelju prvih 50 generacija jedne populacije

Mehanizma sa slike 10. ima vrijednosti geometrijskih parametara dobivenih multikriterijskom optimizacijom na temelju prvih 50 generacija jedne populacije:

$$\begin{aligned} |\vec{r}_1| &= 244 \text{ mm} \\ |\vec{r}_2| &= 830 \text{ mm} \\ |\vec{r}_3| &= 816 \text{ mm} \\ |\vec{r}_5| &= 563 \text{ mm} \\ x_c &= 426 \text{ mm} \\ y_c &= 140 \text{ mm} \\ \alpha &= 235^\circ \end{aligned}$$

S obzirom na mali broj generacija, aproksimacija pravocrtnog gibanja je loša. Povećanjem broja generacija dobiveni su bolji rezultati (slike 7 i 8).

5. ZAKLJUČAK

U radu su sustavno obrađeni pojmovi genetičkih algoritama te njihova primjena kod optimizacije skalarnih matematičkih funkcija i multikriterijske optimizacije putanje četveropolužnog mehanizma. Primjena genetičkih algoritama na prikazanim problemima optimizacije daje zadovoljavajuće rezultate.

Rješenje optimizacijskog algoritma predstavljeno je bitovnim nizom duljine 70 bitova te svakom parametru pripada redom 10 bitova. Svako se rješenje rangira prema Pareto dominaciji. Spremnost rješenja određuje se na osnovu dobivenog ranga te se vrši proporcionalna selekcija nad tako dobivenom populacijom.

Funkcije cilja koje je potrebno minimizirati u slučaju optimizacije parametara četveropolužnog mehanizma su srednje kvadratne pogreške putanje.

Četveropolužni mehanizmi koji su dobiveni multikriterijskom optimizacijom na zadovoljavajući način aproksimiraju dio putanje s pravcem.

Unatoč svim prednostima i atraktivnostima genetičkih algoritama treba imati na umu da oni postaju opcija rješavanja nekog problema ako tradicionalni algoritmi ne daju zadovoljavajuće rezultate ili kada funkcija cilja nije analitička i derivabilna funkcija. Algoritam razvijen specijalno za neki problem u pravilu će dati kvalitetnije i brže rješenje od genetičkog algoritma.

6. LITERATURA

- [1] Sivanandam, S.N.; Deepa, S.N.: *Introduction to Genetic Algorithms*, Springer, Berlin, 2008.
- [2] Norton, R.L.: *Design of Machinery: An Introduction to the Synthesis And Analysis of Mechanisms and Machines*, Second Edition, McGraw-Hill Inc., USA, 1999.
- [3] Goodman, D.; Morrison, M.: *JavaScript Bible*, 5th Edition, Wiley Publishing, Inc., 2004.
- [4] <http://www.artas.nl/en/sam> (Dostupno 8.01.2014.)
- [5] Melaine, M.: *An Introduction to Genetic Algorithms*, MIT Press, Cambridge, Massachusetts, 1999.
- [6] Maretić, M.: Numerička analiza skalarnih matematičkih funkcija bazirana na genetičkim algoritmima, Završni rad, Visoka tehnička škola u Bjelovaru, Bjelovar, 2013.
- [7] Coley, D. A.: *An Introduction to Genetic Algorithms for Scientists and Engineers*, World Scientific Publishing Co. Pte. Ltd., Singapore, 1999.
- [8] Tan, K.C.; Khor, E.F.; Lee, T.H.: *Multiobjective Evolutionary Algorithms and Applications*, Springer-Verlag London Limited, 2005.
- [9] Konak, A.; Coit, D. W.; Smith, A. E.: *Multi-Objective Optimization Using Genetic Algorithms: A Tutorial*, 2005.

Kontakt autora:

Miroslav Maretić, bacc.ing.mech. (bivši student)
e-mail: miroslav.maretic00@gmail.com

Zoran Vrhovski, mag.ing.el.techn.inf.
Visoka tehnička škola u Bjelovaru
Trg Eugena Kvaternika 4
43000 Bjelovar
e-mail: zvrhovski@vtsbj.hr

Dalibor Purković, mag.ing.el.techn.inf.
Visoka tehnička škola u Bjelovaru
Trg Eugena Kvaternika 4
43000 Bjelovar
e-mail: dpurkovic@vtsbj.hr