

DAUGIAKKRITERINIO OPTIMIZAVIMO METODŲ PANAUDOJIMO GALIMYBĖS ANTŽEMINĖSE SAUGOS PRIEMONĖSE

¹Liudas Mašnauskas, ²Jonas Stankūnas

VGTU Antano Gustaičio Aviacijos Institutas

El. p. ¹masnauskas.l@ans.lt; ²jonas.stankunas@vgtu.lt

Santrauka. Straipsnyje apžvelgiama moderni skrydžių valdymo sistema bei antžemių saugos priemonių veikimo priklausomybė nuo sisteminių parametrų rinkinio. Iškeliamas daugiakriterinio optimizavimo uždavinys, nagrinėjami genetiniai optimizavimo algoritmai ir jų panaudojimo galimybė parenkant optimalų sisteminių parametrų rinkinį.


1. Ivadas

Europos oro eismo vadybos (toliau – OEV) sistemos laukia nauji iššūkiai, nes yra prognozuojama, kad per artimiausius dvidešimt metų oro eismo srautas padvigubės (Long-term ... 2010). Naujos skrydžių valdymo sistemos ir technologijos yra reikalingos, kad užtikrintų saugų ir be užlaikymų nenutrūkstamą oro eismo srautą. Europos Komisija inicijavo Bendro Europos dangaus oro eismo tyrimo (angl. – SESAR) programą, kuri turi sukurti ateities OEV sistemą. Ši sistema turės užtikrinti reikiamą oro erdvės pralaidumą ir skrydžių saugos reikalavimus. Norint įgyvendinti SESAR keliamus uždavinius, reikalingos naujos technologijos, kurios apims orlaivio skrydžio trajektorijos vadybą (angl. – Trajectory Management), efektyvius skirsniavimo metodus (angl. – Separation Modes), naujus skrydžių vadovų įrankius (angl. – Controller Tools), patobulintas antžeminės saugos priemonės (angl. – Safety Nets), dinaminę oro erdvės ir sektorių vadybą (angl. – Dynamic Airspace and Sector Management), oras-žemė duomenų perdavimą (angl. – Air Ground Data Link) bei atvykimų ir išvykimų vadybą (angl. – Queue Management). Skrydžių valdymo sistema tampa sudėtingu įrenginiu, kuri naudoja daug informacijos ir duomenų šaltinių, o sisteminių parametrų rinkinys, kurio nustatymas reikalingas kiekvienai aplinkai, tampa pakankamai didelis. Šiuo atveju sisteminių parametrų derinimas administratoriui tampa sudėtingu uždaviniu. Sistemos eksploataciniai rodikliai priklauso būtent nuo to, kiek optimaliai yra parinktas sisteminių parametrų rinkinys. Antžeminės saugos priemonės naudoja orlaivio padėties prognozę, todėl čia ypatingai svarbu, ar sisteminiai parametrai parinkti optimaliai. Tačiau įrangos gamintojas ar administratorius ne visada gali būti sprendimo priėmėju (SP), nes jam gali neužtekti žinių iš skrydžių valdymo ir procedūrų sritys. Projektuojant ir derinant sistemą, susiduriama su optimizavimo problema, nes reikalinga parinkti optimalius parametrus ir atsižvelgti į tam tikrus apribojimus. Sistemos eksploataciniai parametrai, ar kitaip sakant tikslai, gali būti pasiekti keičiant parametrus jų ribose, atliekant bandymus ir priimant sprendimą, kuris parametrų rinkinys yra geresnis. Tokių būdu administratorius, remdamasis savo patirtimi, parenka optimalų rinkinį – Pareto optimalią aibę. Čia galima suformuluoti daugiakriterinio optimizavimo uždavinį. Už-

davinys apima sisteminį parametų keitimą, norint pasiekti optimalius sistemos veikimo parametrus. Parastai šį darbą pradžioje atlieka gamintojas ir sistemos derintojas. Tačiau šis darbas yra nuolatinis, nes keičiasi oro erdvės struktūra ar elementai. Šiame straipsnyje nagrinėjama galimybė automatizuoti sprendimų priėmimą ir parametų parinkimą antžeminėse saugos priemonėse, panaudojant daugiakriterinio optimizavimo algoritmus.

2. Skrydžių valdymo sistemos apžvalga

Skrydžių valdymo sistemos paskirtis yra užtikrinti oro eismo kelionių saugą pateikiant skrydžių vadovams informaciją iš stebėjimo sensorių ir kaimyninių skrydžių valdymo centrų. Informacija yra pateikiama įvairiuose monitoriuose, pavyzdžiui, oro eismo situacija, skrydžių planų informacija ar oro navigacijos informacija (Preliminary ...2008). Apibendrinta skrydžių valdymo sistemos struktūrinė schema matyti 1 paveiksle:



1. Pav. Apibendrinta skrydžių valdymo sistemos struktūrinė schema

Fig. 1. Common air traffic control system structural scheme

Norėtume atkreipti dėmesį į išskirtas sistemos dalis. Pirmoji yra skrydžių vadovo darbo vietos, kuriose pateikiama informacija skrydžių vadovui. Nors šių darbo vietų funkcijos nėra šio tyrimo tema, tačiau būtina paminėti, kad būtent čia parodoma oro eismo situacija, priminimai, konflikto sprendimo patarimai ir antžeminių saugos priemonių perspėjimai. Antžeminės saugos priemonės yra skirstomos taip:

- STCA – padeda skrydžių vadovui išvengti orlaivių suartėjimo, laiku generuojant perspėjimą apie tikėtiną ar esamą skirstymo intervalų pažeidimą (Guidance ... 2009b).
- APW – perspėja skrydžių vadovą apie nesankcionuotą įskridimą į oro erdvę, sugeneruojant perspėjimą apie tikėtiną ar esamą intervalo pažeidimą iki tam tikros oro erdvės (Guidance ... 2009c).
- MSAW – perspėja skrydžių vadovą apie padidėjusią valdomo skrydžio riziką per daug arti priartėti prie žemės paviršiaus arba kliūčių, sugeneruojant perspėjimą (Guidance ... 2009d).
- APM – perspėja skrydžių vadovą apie padidėjusią valdomo skrydžio riziką daug arti priartėti prie žemės paviršiaus arba kliūčių galutinėje artėjimo tūpti fazėje, sugeneruojant perspėjimą (Guidance ... 2009a).

Kontroliuojančios priemonės (angl. – Monitoring AIDS–MONA) stebi skrydžio trajektoriją trijose dimensijose. Jei yra nukrypimai nuo skrydžio plano ar suteikto skrydžio vadovo leidimo, generuojamas perspėjimas ar priminimas skrydžių vadovui. Automatiniai priminimai gali būti generuojami, jei skrydžių vadovas pamiršo atlikti rutininius veiksmus, kuriuos jis turi atlikti tam tikru laiku, priklausomai nuo orlaivio skrydžio trajektorijos (Specification ... 2010). Skrydžių vadovo įrankiai yra tokie (Manual ... 2009):

- CDT – konfliktų aptikimo įrankis
- AMAN – orlaivių atvykimo vadybos įrankis
- DMAN – orlaivių išvykimo vadybos įrankis
- SMAN – antžeminio judėjimo vadybos įrankis.

Konfliktų aptikimo įrankio ir antžeminių saugos perspėjimo priemonių kokybiškas veikimas priklauso nuo orlaivio trajektorijos prognozavimo paklaidų, gautos informacijos iš stebėjimo sensorių, kaimyninių centrų, orlaivio ir visos sistemos aplinkos. Visa sistemos veikimo aplinka yra aprašyta duomenų bazėse. Būtent nuo to, kaip parinkti sisteminiai parametrai, priklauso, koks bus skaičius teisingų ir klaidingų perspėjimų. Pagrindinis tikslas yra sumažinti klaidingų perspėjimų skaičių ir padidinti teisingų perspėjimų skaičių. Tačiau skrydžių valdymo sistemos struktūra ir veikimas yra toks, kad neįmanoma padidinti teisingų perspėjimų skaičiaus nepaveikus klaidingų perspėjimų. Vadinasi, mes turime du tikslus- maksimizuoti teisingų perspėjimų skaičių ir minimizuoti klaidingų perspėjimų skaičių. Šie tikslai gali būti pritaikyti antžeminėms perspėjimo priemonėms, kontroliuojančioms priemonėms ir skrydžių vadovo įrankiams. Kaip jau buvo minėta, šių sistemos sudedamųjų dalių veikimas priklauso nuo sisteminių parametrų parinkimo, kurie gali būti keičiami tam tikrose ribose. Tikslas yra eliminuoti, SP sistemos derinimo procese pritaikant daugiakriterinio optimizavimo algoritmus. Genetiniai optimizavimo algoritmai čia turėtų tikti geriausiai, nes nereikalinga jokia patirtis, o pačių algoritmų veiksmas yra artimi SP veiksmams.

3. Genetinių algoritmų apžvalga

Vienas populiariausių daugiakriterinio optimizavimo metodų klasifikavimo būdų yra pasirenkamas pagal tai, ar

jie generuoja Pareto optimalius sprendinius ir SP vaidmenį šiame procese. Pagrindinis SP vaidmuo yra nuspręsti, ar taškai patenka į Pareto optimalių sprendinių aibę. Metodai, kurie generuoja sprendinius, paprastai leidžia surasti Pareto aibę arba jos aproksimaciją. Šie metodai nenaudoja kriterijų svorių ar prioritetų. Kitoje metodų grupėje SP ar ekspertas reikalingas pirminiuose optimizavimo etapuose. Šie metodai yra vadinami pirmenybės metodais ir jiems yra reikalingi kriterijų svoriai. SP turi suvokti iškeltus tikslus ir nustatyti kriterijų svarbą ar svorius. J. H. Holland (1975) aprašė genetinius algoritmus (GA). Genetiniai algoritmai yra paremti populiacijomis ir gerai tinka spręsti daugiakriterinio optimizavimo uždavinius. Genetiniai algoritmai suteikia galimybę ieškoti sprendinių sprendžiant sudėtingus uždavinius bei surasti sprendinius neiškiliose ir netolydžiose aibėse. GA nereikalauja nustatyti prioritetų, svėrtų ar svorių. Šie algoritmai yra vieni populiariausių euristinių metodų grupėje sprendžiant projektavimo ar optimizavimo uždavinius, kai uždavinys turi kelis tikslus. D. F. Jones pateikė ataskaitą, kad 90% atvejų, kai buvo naudojami GA daugiakriteriniams uždaviniams spręsti, buvo surasta Pareto aibės aproksimacija (Deb *et al.* 2002). Reikia pažymėti, kad GA daugiakriterinio optimizavimo problemą sprendžia tiesiogiai. Be to, jie efektyvūs nepriklausomai nuo problemos pobūdžio ir apribojimų. Šie metodai naudoja atsitiktinę atranką ir informaciją iš prieš tai buvusių iteracijų, kad patobulintų visą populiaciją. Todėl galima daryti prielaidą, kad GA turėtų padėti surasti geriausiai tinkantį sisteminių parametrų rinkinį ar, kitaip sakant, Pareto optimalų sprendinį ar jo aproksimaciją. Šių optimizavimo algoritmų pritaikymo sritys yra labai plačios, pavyzdžiui:

- Kontrolė – dujotiekiai, raketos smūgio išvengimas;
- Projektavimas – puslaidininkiai, orlaivio konstrukcija, ryšių tinklai, statybinės konstrukcijos;
- Tvarkaraščio sudarymas – detalių pristatymas, resursų paskirstymas, maršruto optimizavimas;
- Robotų technika – trajektorijos planavimas;
- Mechanizmo apmokymas – neuroniniai tinklai, klasifikavimo sistemos;
- Signalo apdorojimas – filtrų projektavimas;
- Kombinatorinis optimizavimas – keliaujančio pardavėjo maršrutas;
- Kompiuterių mokslas – operacinės sistemos optimizavimas.

3.1. Paprastas genetinis algoritmas

J. H. Holland pasiūlė naudoti dvejetainiu kodu pagrįstą algoritmą, kuris rėmėsi Darvino natūralios atrankos dėsniais, kai išlieka tinkamiausias individas (Holland 1975). Individas yra gautas atsitiktinai keičiant genų struktūrą. Galima teigti, kad tokiu būdu sukuriamas atsitiktinė individų populiacija arba sprendinys, kuris tenkina iškeltą tikslą. Šio sprendinio parametrai (genai) yra kryžminami, mutuojami ir atrinkami geriausi individai. Tokiu būdu yra sudaromos naujos populiacijos. Remiantis atrankos principu nauji sprendiniai yra geresni arba, kitaip sakant, geriau tenkina tikslus. Šis procesas yra kartojamas iki tol,

kol gaunamas sprendinys, tenkinantis išskeltus tikslus. Paprastas genetinis algoritmas apima šiuos pagrindinius veiksmus: atranką, kryžminimą ir mutavimą. Toliau pateikiame apibendrintą genetinį algoritmą:

1. Pradžia. Atsitiktinės populiacijos P_1 generavimas iš n chromosomų.
2. Tinkamumo vertinimas. Kiekvienos chromosomos vertinimas pagal tinkamumo funkciją.
3. Naujos populiacijos sudarymas. Sudaroma nauja populiacija P_n :
 - Kryžminimas. Nauja atžala (vaikas) gaunamas kryžminant tėvus su tam tikra tikimybe. Atskirais atvejais vaikas gali būti tėvų kopija.
 - Mutavimas. Atžalos genai su tam tikra tikimybe yra mutuojami.
4. Tinkamumo vertinimas. Kiekvienos chromosoma yra vertinama pagal tinkamumo funkciją.
5. Atranka. Atrinkama N sprendinių, remiantis tinkamumo funkcija ir sudaroma nauja populiacija P_{n+1} .
6. Stabdymas. Jei stabdymo kriterijus yra pasiektas, stabdomas procesas, jei ne, tai grįžtame į 3 žingsnį.

3.2. Pradinė populiacija

Pradinė populiacija yra sudaroma atsitiktinai nustatant parametrus tam tikrose ribose. Šie parametrai yra vadinami individo chromosomos genais (Goldberg 1989). Kiekvienas genas kontroliuoja tam tikrą chromosomos savybę. J. H. Holland genus rodo kaip dvejetainius skaičius. GA naudoja chromosomų rinkinius, kurie yra vadinami populiacija. Vykdamas visą paieškos procesą populiacijose atsiranda vis geresni sprendiniai ir tęsiant paiešką – randamas sprendinys, kuris dominuoja tarp visų kitų. J. H. Holland pateikė įrodymą, kad sprendiniai konverguoja link globalaus optimumo, kai chromosomos yra dvejetainiai vektoriai (schemas teorema). Tačiau chromosomos gali būti (Tutorial 2014):

- Bitų rinkinys (0101 ... 1100)
- Realūs skaičiai (43.2 -33.1 ... 0.0 89.2)
- Bet koks elementas (E11 E3 E7 ... E1 E15)
- Taisyklių ar procedūrų rinkinys (R1 R2 R3 ... R22 R23)
- Programos elementai (genetinis programavimas)
- Bet kokie struktūrizuoti duomenys.

Dvejetainės, realių skaičių ir elementų chromosomos yra pavaizduotos žemiau (2–5 pav.):

Šiuo atveju turime 26 kintamus sisteminius parametrus, kurie yra naudojami SCTA skaičiavimuose. Šių parametrų kitimo ribos yra didelės, todėl naudoti dvejetainį kodavimą yra sudėtinga. Tyrimai rodo, kad optimizavimas yra efektyvus ir naudojant realius skaičius (Wright 1991). Galima teigti, kad turime sisteminių parametrų aibę arba parametrų vektorius, sudarytą iš kintamųjų:

$$x = (x_1, x_2, \dots, x_n) \quad (1)$$

Vektorius yra suformuotas iš realių skaičių. Kiekvienas kintamasis kinta tam tikrose ribose. Jie kinta leistinoje srityje arba leistinoje aibėje:

$$A \in R^n \quad (2)$$

Chromosome 1	10011110111101101111
Chromosome 2	0101111011111101101

2 pav. Dvejetainės chromosomos
Fig. 2. Binary coded chromosomes

Chromosome 1	10; 1000; 15; 1000, 0,1
Chromosome 2	20; 1500; 12,5; 1500; 0,5

3 pav. Realių skaičių chromosomos
Fig. 3. Real number coded chromosomes

Chromosome 1	E4; E3; E17; E20; E5
Chromosome 2	E6; E8; E10; E15; E2

4 pav. Elementų chromosomos
Fig. 4. Element coded chromosomes

Chromosome 1	R4; R3; R17; R20; R5
Chromosome 2	R6; R8; R10; R7; R2

5 pav. Taisyklių chromosomos
Fig. 5. Rule coded chromosomes

Galima sudaryti dvi tėvų chromosomas $x = x_1, x_2, \dots, x_m$ (tėvas) ir $y = y_1, y_2, \dots, y_m$ (motina). Tačiau tarp x ir y yra ryšys:

$$y_i = x_i + \lambda \alpha_i \quad (3)$$


čia x_i – tėvo chromosomos geno vertė, α_i – geno kitimo žingsnis, λ – atsitiktinis sveikas skaičius, y_i – kita parametro reikšmė.

Galima teigti, kad turime pirminę populiaciją, sudarytą iš dviejų individų ir galime generuoti vaikus bei sudaryti naujas populiacijas. Tinkamumo funkcija bus aptariama 6 skyriuje.

3.3. Kryžminimas

Turėdami pirminę populiaciją, galime keisti chromosomos genus, tai yra pirminė operacija – kryžminimas. Bendru atveju kryžminimas – tai kelių individų genų sukeitimas. Literatūroje yra aprašoma daug kryžminimo metodų, tačiau vienas populiariausių yra vieno taško pjūvis (Goldberg 1989). Vieno taško pjūvis tėvų chromosomose yra parenkamas atsitiktinai. Tokiu būdu sukeičiami genai ir gaunami nauji individai (vaikai) ir jie tampa populiacijos nariais. Būtent čia pasireiškia GA heuristinė prigimtis, nes reikalinga pasirinkti, kokia tikimybe atrinkami individai kryžminimui ir kokia tikimybe pa-


renkamas pjūvio taškas. Žemiau 6 paveiksle yra parodyta vieno taško pjūvio kryžminimas (Šiuo atveju yra naudojami realūs skaičiai):



6 pav. Vieno taško kryžminimas
Fig. 6. One point crossover

3.4. Mutavimas

Mutavimas – tai toks procesas, kuris leidžia keisti genus ir tokiu būdu atlikti naujų sprendinių paiešką. Kitaip sakant, ieškoti, kokius rezultatus duoda individai su naujais genais. Genai mutavimui yra parenkami atsitiktiniu būdu su tam tikra tikimybe. Jei naudojamos dvejetainės chromosomos, tai tam tikri bitai "keičiami" nuo 0 į 1 arba nuo 1 į 0. Jei naudojami realūs skaičiai, genai yra keičiami pagal tam tikras taisykles. Šiuo atveju galėtų būti naudojama (3) formulė ir atsitiktinai parenkamas geno kitimo žingsnis. Paprastai mutavimo tikimybė yra parenkama maža, todėl tikimybė, kad bus mutuojami daugiau kaip du genai yra maža. Žemiau pateikiamas paveikslas, kuris rodo naujus parametrų rinkinius, kurie buvo gauti naudojant mutavimą:



7 pav. Chromosomos, sudarytos iš realių skaičių mutavimas
Fig.7. Mutation of real coded chromosomes

Geno mutavimo tikimybę reikėtų parinkti mažą, kad tolygiau padengtų Pareto sprendinių paieškos sritį ir būtų išvengta konvergavimo į kurią nors vieną aibės vietą.

3.5. Tinkamumo vertinimas ir atranka

Tinkamumo funkcija leidžia įvertinti, kiek geras yra sprendinys. Tinkamumo funkcija turi būti sudaryta taip, kad geresnis sprendinys gautų aukštesnes reikšmes negu

blogas sprendinys, t. y. nustatyti, kaip sprendinys sprendžia pačią problemą. Tinkamumo funkcija leidžia vykdyti individų atranką. Jei sprendžiama minimizavimo problema, geriausiai tinkantys individai turės mažesnę tinkamumo funkcijos reikšmę. Tačiau tinkamumo funkcija yra naudojama tik tarpiniam individo vertinimui. Reikia pažymėti, kad tinkamumo funkcija yra naudojama tikslo funkcijos transformavimui (Chipperfield *et al.* 1992). Šios funkcijos reikšmės turėtų būti teigiamos. Šiuo atveju turime dvi tikslo funkcijas: $\max f_2(x)$ teisingų perspėjimų skaičius ir $\min f_1(x)$ klaidingų perspėjimų skaičius. Perspėjimų generavimui yra naudojamas vienas algoritmas, todėl šie tikslai yra susiję tarpusavyje. Pirminė tikslo funkcija gali būti išreikšta taip:

$$\max(f_2(x) - f_1(x)) \quad (4)$$

čia $f_2(x)$ – juda link max leistinoje aibėje, $f_1(x)$ – juda link min leistinoje aibėje.

Galima transformuoti šią funkciją:

$$\frac{\min 1}{f_2(x) - f_1(x) + 50} \quad (5)$$

turint galvoje sąlygas (4), kaip išvengti neigiamų reikšmių ir dalybos iš nulio. Tinkamumo funkcija sisteminių parametrų optimizavimui bus aptariama paskutiniame skyriuje.

3.6. Stabdymas

GA yra stochastinis paieškos metodas ir gana sunku tiksliai apibrėžti konvergavimo kriterijų. Populiacijų tinkamumas gali išlikti pastovus iki to momento, kol bus surastas pranašesnis individas. Todėl įprastas stabdymo požymis tampa gana problematišku. Bendrai priimta praktika yra stabdyti procesą po tam tikro iteracijų skaičiaus ir vertinti tinkamiausius populiacijos individus, kaip jie tenkina patį problemos sprendimą. Tuo atveju, jei tinkamų sprendinių nėra GA gali būti kartojamas iš naujo (Chipperfield *et al.* 1992).

4. Tinkamumo funkcijos tipai

Išskiriami trys pagrindiniai tinkamumo funkcijos tipai (Zitzler *et al.* 2004). Tai yra:

- Svertinė suma.
- Paremta atskirų tikslų vertinimu.
- Pareto dominavimo rangų suteikimas.

4.1. Svertinė suma

Klasikinis daugiakriterinio optimizavimo uždavinio sprendimas yra priskirti tam tikrą svorį w_i kiekvienai tikslo funkcijai $f_i(x)$. Šiuo atveju problema yra keičiama vieno tikslo problema:

$$\min f = w_1 f_1(x) + w_2 f_2(x) + \dots + w_n f_n(x) \quad (6)$$

čia $f_i(x)$ yra normalizuota tikslo funkcija ir jų suma $\sum w_i = 1$. Šis metodas yra vadinamas pirmenybės metodu, nes naudotojas turi priskirti tam tikrus svorius. Sprendžiant uždavinį ir naudojant tikslo funkciją (6) tam tikram

svėrtų vektoriui $w = (w_1, w_2, \dots, w_n)$, gaunamas vienas sprendinys. Tuo tarpu, jei reikalingi keli sprendiniai, reikalinga kartoti procesą su kitais svorių variantais. Pagrindinis sudėtingumas yra tas, kad reikia nustatyti svorius kiekvienam paieškai. Tuo tarpu mūsų tikslas yra atsisiakyti svorių nustatymo ir eksperto veiksmų.

4.2. Kintančios tikslo funkcijos

Vektoriaus vertinimo genetinis algoritmas (angl. – Vector Evaluated Genetic Algorithm – VEGA) pirmasis GA naudojo nedominuojamų sprendinių aibę, kad būtų aproksimuota Pareto aibė (Schaffer 1985). Šiame metode populiacija P_t atsitiktinai padalinama į K vienodo dydžio sub-populiacijas $P_1, P_2, \dots, P_K$. Toliau kiekvienam sprendiniui sub-populiacijoje P_i yra priskiriama tinkamumo vertė, kuri priklauso nuo tikslo funkcijos z_i . Sprendiniai iš šių populiacijų yra proporcingai atrenkami kryžminimui ir mutavimui. Tokiu būdu kryžminimas ir mutavimas yra atliekami panašiai kaip ir vieno tikslo optimizavimo uždavinyje. Tai yra kiekvienos atrankos metu yra vertinama tikslo funkcija (Kursawe 1990). Tačiau šis vertinimo metodas sudaro galimybes rasti atskirus čempionus kiekvienam tikslui. Šiuo atveju abu tikslai yra susiję tarpusavyje. Todėl radę klaidingų perspėjimų minimumą, galime už ribos palikti teisingus perspėjimus.

4.3. Pareto rangų metodas

Pirmasis Pareto rangų metodą pasiūlė S. Goldberg (1989). Šis metodas taiko Pareto dominavimą vykdant atranką. Populiacijai yra suteikiamas atitinkamas rangas, priklausomai nuo dominavimo taisyklių. Tai yra individo tinkamumo funkcija įgauna vertę, kuri priklauso nuo rango populiacijoje, o ne nuo tikslo funkcijos. Tačiau GA turi tendenciją, kad sprendiniai kaupiasi tam tikrose vietose. Paprastai yra taikomi du būdai šiam efektui išvengti:

- Tinkamumo pasidalinimas (angl. – Fitness Sharing),
- „Susigrūdimo“ vertinimas (angl. – Crowding Distance).


Todėl šiuo atveju šie metodai turėtų būti taikomi.

5. GA algoritmų apžvalga

5.1. Schafferio vektoriaus vertinimo genetinis algoritmas (angl. vector-evaluated genetic algorithm – VEGA).

Pirmąjį realų evoliucinį daugiakriterinio optimizavimo algoritmą pasiūlė (VEGA) David Shaffer (1985). Jis modifikavo paprastą GA (kryžminimas, mutavimas ir atranka), pridėdamas nepriklausomus atrankos ciklus kiekvienam tikslui. Šiame metode yra atskiras vertinimas pagal kiekvieną tikslo funkciją. Tokiu būdu sudaromos atskiros individų grupės. Toliau visa populiacija sumaišoma ir atliekamas kryžminimas ir mutavimas. Tokie veiksmai leidžia suporuoti skirtingų grupių individus. Supaprastintas VEGA algoritmas yra matyti 8 paveiksle:

Šis algoritmas veikia efektyviai, tačiau turi tendenciją judėti link atskirų tikslų čempionų. Mūsų uždavinyje yra du tikslai, kurie yra susiję tarpusavyje, todėl tikimybė, kad bus surasti individualūs čempionai, gana didelė.




8 pav. VEGA algoritmas

Fig.8. VEGA algorithm

5.2. Daugiakriterinis genetinis algoritmas (angl. Multi-Objective Genetic Algorithm – MOGA)

Šį algoritmą pasiūlė C. M. Fonseca ir P. J. Fleming (1993). Šiame metode kiekvieno individo rangas priklauso nuo to, kiek šioje populiacijoje dominuoja chromosomų. Visi nedominuojami individai gauna aukščiausius rangus. Tuo tarpu dominuojami individai yra baudžiami priklausomai nuo jų populiacijos tankumo. Tai yra vertinama, būtų kiek tankiai yra pasiskirstę individai regione, kad išvengta nišų. Algoritmas pateiktas 9 paveiksle:




9 pav. MOGA algoritmas

Fig. 9. MOGA algorithm

Tačiau reikalinga įvesti tam tikrą evoliucijos strategiją, kadangi ieškomas vienas parametrų vektorius, kuris duoda geriausius rezultatus.

5.3. Nedominuojamų sprendinių rūšiavimo algoritmas II (angl. Non-dominated Sorting Genetic Algorithm II – NSGA-II)

Šį algoritmą pasiūlė K. Deb ir S. Agarwal (Deb *et al.* 2002). Tai patobulintas NSGA variantas. Šis algoritmas vertina sprendinių tankumą apie tam tikrą sprendinį populiacijoje. Ši reikšmė yra vadinama susigrūdimo nuotoliu (angl. – Crowding Distance). Atrankos metu yra vertinamas individo rangas, kuris suteikiamas remiantis dominuojančiais sprendiniais, susigrūdimo nuotoliais. Tai yra nedominuojami sprendiniai turi pirmenybę, tačiau jei sprendiniai turi tą patį rangą, tai atrenkamas sprendinys, kuris yra mažiau tankioje zonoje. Šiame metode naudojamas kitokio pobūdžio elitizmas. Jis yra paremtas geriausių tėvų ir vaikų apjungimu. Supaprastintas algoritmas yra matyti 10 paveiksle:




10 pav. NSGA-II algoritmas

Fig. 10. NSGA-II algorithm

5.4. Pareto evoliucijos jėgos algoritmas (angl. – Strength Pareto Evolutionary Algorithm – SPEA)

Šį algoritmą pasiūlė E. Zitzler ir L. Thiele (1999). Šis metodas naudoja nedominuojamų sprendinių archyvą, kurie buvo rasti ankstesnėse iteracijose. Toks archyvas yra vadinamas išorine nedominuojamų sprendinių aibe. Kiekvienam individui yra skaičiuojama jėgos vertė. Jėgos vertės skaičiavimas yra panašus į rango suteikimą MOGA (Fonseca, Fleming 1993), nes jis yra proporcingas sprendinių skaičiui, kuriuose jis dominuoja. Kiekvieno populiacijos individo tinkamumas yra vertinamas pagal tai, kokiuose sprendiniuose jis dominuoja išorinėje aibėje. Vadinasi, tinkamumo procesas vertina sprendinio artumą Pareto frontui ir sprendinių tolygumo pasiskirstymą vienu metu. Vadinasi vietoj nišų vertinimo naudojamas Pareto dominavimas. Tai leidžia užtikrinti, kad Pareto frontas bus tolygiai padengtas. Supaprastintas algoritmas matyti 11 paveiksle:

Šio metodo efektyvumas priklauso nuo išorinės nedominuojamų sprendinių aibės dydžio. Gali atsitikti taip, kad ši aibė taps labai didelė. Todėl būtina apriboti jos dydį.




11 pav. SPEA algoritmas

Fig. 11. SPEA algorithm

5.5. Pareto evoliucijos strategijos archyvo algoritmas (angl. – Pareto Archived Evolution Strategy – PAES)

PAES algoritmą pasiūlė J. D. Knowles ir D. W. Corne (1999). PAES naudoja vadinamą 1 + 1 evoliucijos strategiją. Tai yra vienas tėvas generuoja vieną vaiką ir įrašo ankščiau rastus nedominuojamus sprendinius į archyvą. Archyvas yra naudojamas kaip etaloninė aibė, su kuria yra lyginamas kiekvienas mutuoatas individas. Šis istorinis archyvas gali būti vadinamas elitizmo mechanizmu. Būtent šis specialus procesas leidžia užtikrinti sprendinių įvairovę. Kiekvienas sprendinys yra patalpinamas į tam tikrą tinklėlį. Sprendinio koordinatės nustatomos pagal tikslo funkciją. Algoritmas matyti 12 paveiksle:



12 pav. PAES algoritmas

Fig. 12. PAES algorithm

Koordinatinis tinklėlis padeda nustatyti sprendinių susibūrimo vietas ir eliminuoti nepageidaujamus sprendinius.

6. Tinkamumo funkcijos SPEA ir PAES

Apžvelgus keletą genetinių algoritmų iš inžinerinės pusės galima daryti išvadą, kad SPEA ir PAES yra artimi SP ir sistemos derintojo veiksmams. Tai yra SP keičia sisteminius parametrus, atlieka bandymus, vertina rezultatus ir atrenka geriausius. Kaip jau buvo minėta SPEA turi dvi individų populiacijas. Vieną jų sudaro dominuojantys ir dominuojami sprendiniai $-P$. Tuo tarpu archyvą sudaro tik elitiniai dominuojantys sprendiniai $-P'$. Pastarųjų tinkamumas yra vertinamas pagal rangus. Individo populiacijos P' , stiprumo vertė tiesiogiai proporcinga dominuojamų sprendinių aibėje P :

$$S_i \in [0, 1] \quad (6)$$

Tuo tarpu tinkamumo reikšmė yra skaičiuojama taip:


$$\frac{F_i(x)1}{f_2(x_i) - f_1(x_i) + 50} \quad (7)$$

Tuo atveju, jeigu P' aibės sprendinį dominuoja P aibės sprendinys, tai jis yra perduodamas į archyvą. Tuo tarpu P' dominuojamas sprendinys yra pašalinamas.

PAES algoritme yra panašiai skaičiuojama tikslo funkcija (7). Tačiau papildomai yra vertinamas „susigrūdimas“. Koordinatės galėtų būti klaidingų ir teisingų perspėjimų skaičius:

$$X = f_1(x_i), Y = f_2(x_i) \quad (8)$$

Tai turėtų atrodyti (13 pav.) taip:




13 pav. Koordinatinis tinklėlis

Fig. 13. Coordinate grid

Vadinasi mes galime įvertinti sprendinių tinkamumą be SP įsikišimo.

7. Eksperimentinių tyrimų schemas


Eksperimento metu naudojamas pratimų rengimo įrankis, skrydžių valdymo treniruoklis ir genetinių algoritmų programinė įranga MATLAB. Struktūrinė schema matyti 14 paveiksle:



14 pav. Eksperimentinių tyrimų schema

Fig. 14. Experimental research scheme

Pratimų rengimo įrankis leidžia sudaryti skrydžių trajektorijas, kurios konfliktuoja arba yra ties konflikto riba. MATLAB programa leidžia generuoti sisteminių parametrų rinkinius. Jie perduodami skrydžių valdymo treniruokliui. Atliekamas bandymas ir registruojami perspėjimai. MATLAB leidžia vertinti sisteminių parametrų rinkinius pagal tinkamumo funkciją. Tokiu būdu yra atliekamos iteracijos (15 pav.).



15 pav. Duomenų sulginimas.

Fig. 15. Data comparison

Gauti sprendiniai gali būti patikrinti realiomis sąlygomis. Tam gali būti naudojama techninė platforma, kurioje įvesti gauti sisteminiai parametrai ir ji dirba tokioje pačioje aplinkoje, kaip ir veikianti skrydžių valdymo sistema. Tuo tarpu veikianti sistema naudoja originalų sisteminių parametrų rinkinį. Gauti perspėjimai gali būti sulgininti.

Išvados

1. Genetinių algoritmų pritaikymas yra plačiai taikomas įvairių projektavimo uždavinių sprendimui. Jis gali būti pritaikytas skrydžių valdymo sistemos sisteminių parametrų optimizavimui.
2. Tradiciniuose genetiniuose algoritmuose chromosomos yra koduojamos dvejetainiu kodu. Sisteminių parametrų optimizavimo atveju tokio kodavimo naudojimas yra komplikotas, nes parametrų ribos yra plačios. Šiuo atveju būtų patogiau naudoti realius skaičius.
3. Apžvelgus genetinius optimizavimo algoritmus, galima teigti, kad SPEA ir PAES yra vieni artimiausių SP veiksmams.

Literatūra

- Deb, K.; Pratap, A.; Agarwal, S., *et al.* 2002. A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE, Transactions on Evolutionary Computation* 6(2): 182–197.
- Chipperfield, A.; Peter Fleming, P.; Pohlheim, H., *et al.* 1992. *Genetic Algorithm TOOLBOX Version 1.2. User's Guide*

Automatic Control and Systems. Engineering University of Sheffield.

- Goldberg, S. 1989. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, Reading, Mass.
- Guidance Material for Approach Path Monitor*. 2009a EUROCONTROL, vol. 1.0.
- Guidance Material for Area Proximity Warning*. Appendix A: Reference APW System. 2009b. EUROCONTROL.
- Guidance Material for Minimum Safe Altitude Warning*. 2009c. EUROCONTROL, vol.1.0.
- Guidance Material for Minimum Safe Altitude Warning*. Appendix A: Reference MSAW System. 2009d EUROCONTROL, vol. 1.0.
- Holland, J. H. 1975. *Adaptation in Natural and Artificial Systems*. U.: Michigan Press, Ann Arbor, Mich.
- Fonseca, C. M., Fleming, P. J. 1993. Genetic algorithms for multiobjective optimization: formulation, discussion and generalization, in *Proc. of the 5th International Conference on Genetic Algorithms*. San Mateo, California, University of Illinois at Urbana-Champaign. Forrest, S. ed. California: Morgan Kauffman Publishers.
- Knowles, J. D. Corne, D. W. 1999. The Pareto archived evolution strategy: a new baseline algorithm for Pareto multiobjective optimization, in *Proceedings of the Congress on Evolutionary Computation (CEC'99)*, 98–105.
- Kursawe, F. 1990. A variant of evolution strategies for vector optimization, in *Parallel Problem Solving from Nature: 1st Workshop. Proceedings*.
- Long-Term Forecast. Flight Movements 2010–2030*. 2010. EUROCONTROL, vol.1.0.
- Manual Guidelines for FASTI Tools Implementation*. 2009. FASTI ATC, vol. 1.0.
- Preliminary Reference System/Subsystem Specification for the Air Traffic Control Automation System. 2008. ICAO.
- Schaffer, J. D. 1985. Multiple objective optimization with vector evaluated genetic algorithms, in *International Conference on Genetic Algorithm and their applications*.
- Specification for Monitoring Aids*. 2010. EUROCONTROL, vol. 1.0.
- Tutorial [interaktyvus] .2014. [žiūrėta 2014 m. sausio 15 d.]. Prieiga per internetą: <http://www.scribd.com/doc/132191399/Ga-Tutorial>
- Wright, A. H. 1991 Genetic algorithms for real parameter optimization, *Foundations of Genetic Algorithms* 1: 205–218.
- Zitzler, E.; Laumanns, M.; Bleuler, S. A 2004. Tutorial on evolutionary multiobjective optimization, *Metaheuristics for Multiobjective Optimisation* 535: 3–37.
- Zitzler, E.; Thiele, L. 1999. Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach, in *IEEE Transactions on Evolutionary Computation* 3(4): 257–271.

tal scheme for research and obtained parameter set validation is proposed in the end of article.

Keywords: Safety Nets, STCA, APW, MSAW, VEGA, NSGA-2, SPEA, PAES.

MULTI-PARAMETER OPTIMIZATION METHOD USAGE OPPORTUNITY ABOVE-GROUND SECURITY IMPLEMENTS

L. Mašnauskas, J. Stankūnas

Summary

Article analyzes Safety Nets optimization problems, describes simple genetic algorithm and popular genetic algorithms, compares their similarity to decision maker actions. The experimen-