



Romanas PUIŠA

**ADAPTYVIEJI STOCHASTINIAI ALGORITMAI
MECHANINIŲ SISTEMŲ ELEMENTAMS
OPTIMIZUOTI**

Daktaro disertacijos santrauka
Technologijos mokslai, mechanikos inžinerija (09T)

1176

Vilnius



2005

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

Romanas PUIŠA

**ADAPTYVIEJI STOCHASTINIAI ALGORITMAI
MECHANINIŲ SISTEMŲ ELEMENTAMS
OPTIMIZUOTI**

Daktaro disertacijos santrauka
Technologijos mokslai, mechanikos inžinerija (09T)

Vilnius  **2005**

Disertacija rengta 2001–2005 metais Vilniaus Gedimino technikos universitete.

Mokslinis vadovas

prof. habil. dr. Vladas VEKTERIS (Vilniaus Gedimino technikos universitetas, technologijos mokslai, mechanikos inžinerija – 09T).

Disertacija ginama Vilniaus Gedimino technikos universiteto Mechanikos inžinerijos mokslo krypties taryboje:

Pirmininkas

prof. habil. dr. Genadijus KULVIETIS (Vilniaus Gedimino technikos universitetas, technologijos mokslai, mechanikos inžinerija – 09T).

Nariai:

prof. habil. dr. Mečislovas MARIŪNAS (Vilniaus Gedimino technikos universitetas, technologijos mokslai, mechanikos inžinerija – 09T),

prof. habil. dr. Marijonas BOGDEVIČIUS (Vilniaus Gedimino technikos universitetas, technologijos mokslai, mechanikos inžinerija – 09T),

prof. habil. dr. Ramutis Petras BANSEVIČIUS (Kauno technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T),

prof. habil. dr. Vytautas OSTAŠEVIČIUS (Kauno technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T).

Oponentai:

habil. dr. Leonidas SAKALAUSKAS (Matematikos ir informatikos institutas, fiziniai mokslai, informatika – 09P),

prof. habil. dr. Algirdas BARGELIS (Kauno technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T).

Disertacija bus ginama viešame Mechanikos inžinerijos mokslo krypties tarybos posėdyje 2005 m. spalio 19 d. 14 val. Vilniaus Gedimino technikos universiteto senato posėdžių salėje.

Adresas: Saulėtekio al. 11, LT-10223 Vilnius-40, Lietuva.

Tel.: +370 5 274 49 52, +370 5 274 49 56; faksas +370 5 270 01 12, el. paštas doktor@adm.vtu.lt

Disertacijos santrauka išsiuntinėta 2005 m. rugsėjo 19 d.

Disertaciją galima peržiūrėti Vilniaus Gedimino technikos universiteto bibliotekoje (Saulėtekio al. 14, Vilnius, Lietuva).

VG TU leidyklos „Technika“ 1176 mokslo literatūros knyga

© Romanas Puiša, 2005

VILNIUS GEDIMINAS TECHNICAL UNIVERSITY

Romanas PUIŠA

**THE ADAPTIVE STOCHASTIC ALGORITHMS
FOR STRUCTURE OPTIMISATION OF
MECHANICAL PARTS**

Summary of Doctoral Dissertation
Technological Sciences, Mechanical Engineering (09T)

Vilnius  2005

Doctoral dissertation was prepared at Vilnius Gediminas Technical University in 2001–2005.

Scientific supervisor

Prof Dr Habil Vladas VEKTERIS (Vilnius Gediminas Technical University, Technological Sciences, Mechanical Engineering – 09T)

The Dissertation is being defended at the Council of Scientific Field of Mechanical Engineering at Vilnius Gediminas Technical University:

Chairman

Prof Dr Habil Genadijus KULVIETIS (Vilnius Gediminas Technical University, Technological Sciences, Mechanical Engineering – 09T)

Members:

Prof Dr Habil Mečislovas MARIŪNAS (Vilnius Gediminas Technical University, Technological Sciences, Mechanical Engineering – 09T)

Prof Dr Habil Marijonas BOGDEVIČIUS (Vilnius Gediminas Technical University, Technological Sciences, Mechanical Engineering – 09T)

Prof Dr Habil Ramutis Petras BANSEVIČIUS (Kaunas University of Technology, Technological Sciences, Mechanical Engineering – 09T)

Prof Dr Habil Vytautas OSTAŠEVIČIUS (Kaunas University of Technology, Technological Sciences, Mechanical Engineering – 09T)

Opponents:

Dr Habil Leonidas SAKALAIŠKAS (Institute of Mathematics and Informatics, Physical Sciences, Informatics – 09P)

Prof Dr Habil Algirdas BARGELIS (Kaunas University of Technology, Technological Sciences, Mechanical Engineering – 09T)

The dissertation will be defended at the public meeting of the Council of Scientific Field of Mechanical Engineering in the Senate Hall of Vilnius Gediminas Technical University at 2 p. m. on 19 October 2005.

Address: Saulėtekio al. 11, LT-10223 Vilnius-40, Lithuania

Tel.: +370 5 274 49 52, +370 5 274 49 56; fax +370 5 270 01 12, e-mail doktor@adm.vtu.lt

The summary of the doctoral dissertation was distributed on 19 October 2005. A copy of the doctoral dissertation is available for review at the Library of Vilnius Gediminas Technical University (Saulėtekio al. 14, Vilnius, Lithuania)

IVADAS

Šiame darbe nagrinėjamas stochastinių algoritmų vystymas ir taikymas mechaninių sistemų elementų geometrijai optimizuoti. Inžinerinėje praktikoje geometrijos optimizacijos uždaviniai dažniausiai yra netiesiniai, turintys triukšmo komponentų, diskretiniai – išreikšti skaičių eilutėmis, o tikslo funkcija ir apribojimai gali būti netolydūs. Jiems spręsti geriausiai tinka stochastiniai metodai. Tai įrodo daugybės sėkmingų stochastinių algoritmų (pvz., *evoliucinių algoritmų*) taikymas tokiems optimizacijos uždaviniams išspręsti, kuriems deterministiniai metodai (pvz., *gradiento metodai*) beveik netinka.

Inžinerinėje praktikoje mechaninių sistemų elementų geometrija optimizuojama ją *parametrizuojant* – apibrėžiant optimizacijos kintamuosius ir *taikant optimizacijos algoritmą* – randant optimalias šių kintamųjų reikšmes. Geometrijos parametrizacijos būdo pasirinkimas lemia optimizacijos uždavinio sprendimo kokybę ir daro įtaką optimizacijos algoritmo pasirinkimui. Todėl efektyvių parametrizacijos ir optimizacijos metodų plėtotė yra du lygiavertės svarbos uždaviniai, sprendžiami mechanikos inžinerijoje. Šiame darbe nagrinėjama tik optimizacijos metodų plėtra, kai optimizacijos kintamieji yra realieji – tolydūs skaičiai.

Darbo motyvacija. Sparčiai didėjanti skaičiuojamosios technikos galia (pastebėta, kad ji kiekvienais metais didėja 1,8 karto) leidžia efektyviai taikyti stochastinius, arba tikimybinus, optimizacijos metodus mašinų projektavimo uždaviniams spręsti. Galima išskirti du pagrindinius šių metodų pasirinkimo motyvus:

- Stochastiniai optimizacijos metodai, palyginti su deterministiniais, vykdo optimalaus sprendimo paiešką skaičiuojant tik tikslo funkcijos reikšmes, t. y. šie metodai nereikalauja tikslo ir apribojimų funkcijų išvestinių ir jų tolydumo bei iškilumo sąlygų, kurios paprastai nepatenkinamos inžinerinėje praktikoje.
- Stochastinius algoritmus, palyginti su deterministiniais, yra daug paprasčiau realizuoti bei pritaikyti konkrečiam optimizacijos uždaviniui spręsti. Todėl šie metodai sparčiai plinta ir jau yra interguoti į populiariausius mašinų projektavimo įrankius, pvz., *CATIA*¹, *Optistruct*², *TOSCA.topology*³, *MSC.Nastran Optimization*⁴ ir *ANSYS*⁵.

¹ <http://www.catia.com>

² http://www.altair.com/software/hw_os.htm

³ <http://www.fe-design.de>

⁴ <http://www.mssoftware.com>

Darbo tikslas. Šio darbo tikslas yra sukurti ir pagrįsti originalius optimizacijos metodus mechaninių sistemų elementų geometrijai optimizuoti. Šie nauji optimizacijos metodai yra kuriami evoliucinių algoritmų ir *paprastos Monte Karlo paieškos* pagrindu. Siekiant šio tikslo reikia:

1. Sukurti ir pagrįsti evoliucinių algoritmų konvergavimo pagerinimo metodus.
2. Sukurti ir pagrįsti alternatyvųjį stochastinį algoritmą inžineriniams uždaviniams su aprobojimais spręsti.
3. Palyginti pasiūlytų optimizacijos metodų efektyvumą praktiniams mašinių projektavimo uždaviniams spręsti.

Mokslinis naujumas

1. Darbe sukurtas originalus tikslo funkcijos paviršiaus analizės metodas sudaro sąlygas prognozuoti stochastinio algoritmo efektyvumą optimizacijos metu. Šis metodas – fundamentali koncepcija, leidžianti spręsti tokius stochastinių algoritmų konvergavimo pagerinimo klausimus, kaip stochastinės paieškos prisitaikymo prie tikslo funkcijos paviršiaus. Tai padaryta šiame darbe.
2. Pristatytas originalus evoliucinių algoritmų konvergavimo pagerinimo metodas – statistine jautrumo analize pagrįstas mutacijos operatorius. Evoliuciniai algoritmai su nauju mutacijos operatoriumi įgyja kur kas geresnių konvergavimo savybių (netiesinio programavimo uždaviniams), palyginti su standartiniais evoliuciniais algoritmais.
3. Sukurtas alternatyvus stochastinis algoritmas padeda efektyviai spręsti tiesinio ir netiesinio programavimo uždavinius, kurių teorinis optimumas yra tikslo ir apribojimų funkcijų sankirtoje.

Tyrimų metodika. Empiriniai pristatomų metodų tyrimai atlikti naudojantis *EO*⁶ (angl. *evolving objects*) programinės bibliotekos baze. Biblioteka sukurta ANSI-C++ programavimo kalba, yra lengvai praplečiama ir suteikia galimybę optimizuoti funkcijas pagrindiniais evoliuciniais algoritmais, t. y.: *genetinėmis algoritmais, evoliucinėmis strategijomis, genetiniu programavimu, evoliuciniu programavimu*. Grafinė tyrimų rezultatų analizė atlikta ir duomenys vaizduojami naudojant *LINUX* operacinėje sistemoje paplitusį *GNUPLOT*⁷ programinį paketą.

⁵ <http://www.ansys.com>

⁶ <http://eodev.sourceforge.net>

⁷ <http://www.gnuplot.info>

Mechaninių sistemų analizė baigtiniais elementais (BE) buvo atlikta naudojant FeLyX⁸ BE biblioteką ir intergruotą į CATIA sistemą BE sprendikli. O geometriniai modeliai BE analizei buvo parengti atitinkamai ANSYS ir CATIA geometrinio modeliavimo aplinkose.

Praktinė vertė. Siūlomų metodų taikymas inžinerinėje praktikoje leidžia efektyviau spręsti sudėtingus mechaninių sistemų optimizacijos uždavinius, nes:

- Naudojant evoliucinius algoritmus su geresnėmis konvergavimo savybėmis, skaičiuojama mažiau tikslo funkcijos reikšmių optimaliam sprendimui rasti. Tai reiškia, jog konkrečiam uždaviniui spręsti reikia skirti mažiau laiko, o tai sutrumpina visą projektavimo ciklą.
- Alternatyvus stochastinis algoritmas siūlo naują teorinių ir praktinių uždavinių sprendimo metodą, kuris taip pat skirtas tikslo funkcijos reikšmių skaičiavimams – algoritmo iteracijoms sumažinti.
- Sukurti metodai pateikiami kaip programinės įrangos paketas, kuris gali būti integruotas į populiariausias mašinų projektavimo sistemas (pvz., *CATIA*) ir taikomas kasdienėje inžinerinėje praktikoje.

Ginamieji teiginiai. Pagrindiniai ginamieji disertacijos teiginiai yra šie:

- Disertacijoje pristatomi keturi originalūs funkcijų optimizacijos metodai, kurie prisideda prie stochastinės optimizacijos problematikos sprendimo.
- Pirmasis metodas – fundamentali koncepcija, leidžianti naujai nagrinėti tikslo funkcijos paviršiaus struktūrą.
- Antrasis metodas yra praktinė pirmosios koncepcijos realizacija. Šis metodas skirtas evoliuciniams algoritmams ir leidžia išspręsti prisitaikymo prie tikslo funkcijos paviršiaus klausimą, o dėl to optimizacijos procesas tampa efektyvesnis.
- Trečiasis metodas pristato naują mutacijos operatorių, skirtą evoliuciniams algoritmams. Teorinė ir empirinė šio metodo analizė įrodė jo sukūrimo pagrįstumą.
- Ketvirtasis metodas – originalus stochastinis algoritmas, leidžiantis naujai spręsti teorinius ir praktinius optimizacijos uždavinius su apribojimais. Kadangi čia optimumas ieškomas tik ties leistinosios aibės ribomis, algoritmas yra veiksmingas sprendžiant dažnai pasitaikančius praktinius inžinerinius uždavinius.

⁸ <http://felyx.sourceforge.net/>

- Praktinių mašinų projektavimo uždavinių sprendimas, taikant disertacijoje pristatytus metodus, įrodo jų efektyvumą, palyginti su plačiai taikomais standartiniais evoliuciniais algoritmais.

Disertacijos struktūra. Disertacija susideda iš dviejų pagrindinių dalių. I – metodų pristatymas ir teorinis jų pagrindimas. Šią dalį sudaro keturi skyriai. II dalis – praktinių mašinų projektavimo uždavinių sprendimas. Šią dalį sudaro du skyriai. Prieš tai įvardiniame skyriuje pristatoma tyrimų sritis ir darbo motyvai, naujumas bei tikslai, o literatūros apžvalgos skyriuje atliekama susijusių tyrimų ir metodų apžvalga. Disertacijos pabaigoje – bendrosios išvados. Po jų pateikti penki priedų skyreliai. Disertaciją sudaro 210 puslapių.

Publikacijos. Darbe pristatomi tyrimai buvo aprobuoti tarptautinėse konferencijose, užsienio konferencijose ir recenzuojamuose žurnaluose. Publikacijų sąrašas pateiktas 26 puslapyje.

DARBO TURINYS

Pirmąją disertacijos dalį sudaro keturi skyriai, kurių kiekvienas atitinka vieną iš pristatomų disertacijoje metodų. **Trečiame skyriuje** pristatomas tikslo funkcijos analizės būdas. Kadangi tyrimai atliekami su evoliuciniais algoritmais, čia naudojama tariamojo tikslo funkcija, kuri vadinama *vetės funkcija* (angl. *fitness function*). Paprastai (taikant populiarų baudos metodą) ji yra tikslo funkcijos ir uždavinio apribojimų funkcijų suma, t. y.:

$$F = w_0 f'(\vec{x}) + \sum_{i=1}^m w_i c'_i(\vec{x}), \quad (1)$$

čia F – vetės funkcija; f' – normalizuota tikslo funkcija; c'_i – normalizuotas i -tasis apribojimas iš m esančių; $w_0 + \sum_{i=1}^m w_i = 1$ – svorio koeficientai, nusakantys kiekvieno vertės funkcijos komponento santykinį reikšmingumą. Vertės funkcijos paviršiaus struktūros tyrimas yra svarbus, nes leidžia nusakyti optimizacijos uždavinio sudėtingumą. Tyrimo metu buvo suformuluotos dvi hipotezės:

1. Taškų populiacijos vertės keičia savo pasiskirstymą, atsižvelgiant į vertės funkcijos paviršiaus regiono formą, ant kurio ši populiacija yra pasklidusi.

2. Populiacijos taškų verčių dažnių pasiskirstymas gali būti nagrinėjamas Gausso pasiskirstymo atžvilgiu.

Buvo taikomi tokie populiacijos taškų verčių dažnių pasiskirstymo tyrimo metodai:

- Gausso pasiskirstymo *asimetriškumas*, kuris yra trečiosios eilės statistinis momentas.
- Gausso pasiskirstymo *ekscesas*, kuris yra ketvirtosios eilės statistinis momentas, nusakantis pasiskirstymo plokštumą.
- Geriausios *vertės dažnis* (2) – tai geriausio populiacijos taško, t. y. taško su mažiausia vertės funkcijos reikšme, esant minimizacijos uždaviniui, arba taško su didžiausia vertės funkcijos reikšme, esant maksimizacijos uždaviniui, dažnis. Šis dažnis pasako, kiek taškų populiacijoje turi tas pačias vertės funkcijos reikšmes kaip ir geriausias populiacijos taškas. Šis matas pasiūlytas disertacijos autoriaus.

$$\omega_b = \frac{1}{\Pi} \sum_{\substack{j=1 \\ j \neq i}} \delta_j, \quad (2)$$

$$\delta_j = \begin{cases} 1: & F_j \in [F_b - \varepsilon, F_b + \varepsilon], \\ 0: & \text{priešingai,} \end{cases} \quad (3)$$


čia $\omega_g \in [0,1)$ – geriausios vertės F_b dažnis; Π – populiacijos dydis; F_j – j -ojo taško vertės reikšmė; ε – intervalo dydis aplink geriausių vertės reikšmę F_b . Šiame darbe intervalo dydis buvo imamas kaip 5 % nuo geriausios vertės, t. y. $\varepsilon = 0.05F_b$.

Empiriniai tyrimai parodė, jog aukštesniosios eilės momentai, t. y. asimetriškumas ir ekscesas, nėra patikimi vertės funkcijos tyrimo įrankiai dėl šių priežasčių:

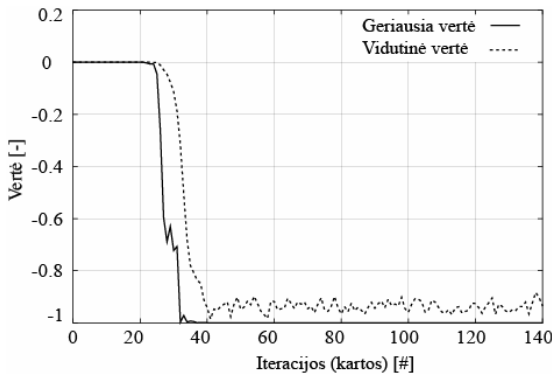
1. Yra nestabilūs, nes yra atvirkščiai proporcingi standartiniam nuokrypiui, t. y. artėja iki begalybės, kai vardiklis artėja prie nulio. Tokia situacija susiklosto, kai tikslo funkcijos paviršius yra plokščias (žr. 1 pav.).
2. Kadangi asimetriškumas ir ekscesas parodo pasiskirstymo nuokrypius tik nuo dvimačio Gausso pasiskirstymo, vertės funkcijos paviršius

nusakymo paklaida didėja didėjant uždavinio matui ir populiacijos pasklidimo lygiui. Šie matai būtų efektyvūs, jei populiacijos taškai būtų pasklidę palei tiesę, suprojektuotą ant vertės funkcijos paviršiaus. Bet ir tokiu būdu šie matai nusakytų tik tą paviršiaus dalį, ant kurios ši tiesė yra.

Savo ruožtu geriausios vertės dažnis leidžia nustatyti vertės funkcijos plokštumą, daugiaoptimalumą ir nuožulnumą – greitą algoritmo konvergavimą. Geras pavyzdys yra Easomo teorinė funkcija, kuri turi didelį plokščią paviršių ir vieną globalų minimumą (žr. 1 pav.).




1 pav. Easomo teorinė testavimo funkcija



2 pav. Evoliucinio algoritmo konvergavimas optimizuojant Easomo funkciją

Kaip parodyta 2 pav., algoritmas stagnuoja apytiksliai iki 20 iteracijos, nes visa populiacija pasklidusi ant plokščio tikslo funkcijos paviršiaus. Toliau algoritmas randa įdubimą ir greitai konverguoja iki optimumo. 3 pav. rodoma, kaip geriausios vertės dažnis atspindi tikslo funkcijos paviršių bei algoritmo konvergavimo pobūdį.




3 pav. Geriausios vertės dažnis optimizuojant Easomo funkciją

Taigi geriausios vertės dažnis artėja iki savo didžiausios reikšmės – vieneto, kai vertės funkcijos regionas yra plokščias; svyruoja apie savo vidutinę reikšmę – 0,5, kai algoritmas susiduria su daugiaoptimalumo problema; krinta iki savo minimalios reikšmės, kai algoritmas greitai konverguoja.

Ketvirtame skyriuje nagrinėjamas evoliucinių algoritmų mutacijos prisitaikymo prie vertės funkcijos paviršiaus klausimas. Prisitaikymo esmė – mutacijos intensyvumas yra proporcingas geriausios vertės dažniui. Skyriuje pristatomi du mutacijos tikimybės ir vienas mutacijos žingsnio prisitaikymo metodai. Mutacijos tikimybei prisitaikyti pasiūlyti tikimybinis ir deterministinis prisitaikymo būdai, o mutacijos žingsniui – tik deterministinis būdas.

Tikimybinis mutacijos tikimybės prisitaikymo metodas yra paremtas normaliniu pasiskirstymu su „plaukiojančiu“ vidurkiu. Grafinė to interpretacija pateikta 4 pav. Kaip parodyta 4 pav., mutacijos tikimybė svyruoja apie vidutinę savo reikšmę $\overline{P_m}$, kai konvergavimo greitis yra didelis arba vidutinis, ir pakyla iki savo maksimalios reikšmės P_m^x , kai konvergavimas yra lėtas. Matematiškai mutacijos tikimybė P_m^p apskaičiuojama tokiu būdu:

$$P_m^p = \overline{P_m} + \frac{N(\mu, \sigma_m^2)}{d}, \quad (4)$$



4 pav. Mutacijos tikimybės svyravimas tarp minimalios P_m^n ir maksimalios reikšmės P_m^x . Normaliojo pasiskirstymo vidurkis $\mu \in [0, 3\sigma]$ svyruoja atsižvelgiant į algoritmo konvergavimo greitį: didelį, vidutinį ir lėtą

o normaliojo pasiskirstymo vidurkis ir standartinis nuokrypis apskaičiuojami taip:

$$\mu = 3\sigma_m(1 - Q), \quad (5)$$

$$\sigma_m = \frac{P_m^x - P_m^n}{6}, \quad (6)$$

čia dydis Q vadinamas *sėkmės tikimybe*, kuri nusako algoritmo konvergavimo tikėtumą būsimose iteracijose. Ši tikimybė yra proporcinga geriausios vertės dažnio ω_b paskutinių iteracijų vidurkiui:

$$Q = 1 - \frac{\overline{\omega_b}}{\xi}. \quad (7)$$


Formulėse (4) ir (7) naudojami koeficientai d ir ξ yra atitinkamai slopinimo ir sąryšio koeficientai, kurie detaliau aprašyti pagrindiniame disertacijos tekste.

Deterministinis mutacijos tikimybės paskaitymo būdas išreiškiamas taip:

$$P_m^d = \overline{P}_m + \frac{\mu}{d}, \quad (8)$$

t. y. čia mutacijos tikimybė tiesiai proporcinga normaliojo pasiskirstymo vidurkiui, apskaičiuotam pagal formulę (5). Pažymėtina, kad čia mutacijos tikimybė niekada nebūna mažesė už vidutinę savo reikšmę \overline{P}_m .

Mutacijos žingsnio s prisitaikymo schema pavaizduota 5 pav. Čia prisitaikymas vyksta atsižvelgiant į koeficiento κ reikšmę, kuris nusako vidurkio μ' dydį, kurį viršijus mutacijos žingsnio reikšmė didėja. Todėl koeficientas κ yra dar vadinamas *mutacijos žingsnio slenkščiu*, o jo dydis nustatomas optimizacijos pradžioje, atsižvelgiant į patį optimizacijos uždavinį.



5 pav. Mutacijos žingsnio prisitaikymo schema

Šioje schemoje normaliojo pasiskirstymo vidurkis skaičiuojamas pagal formulę (9), kuri atsieja mutacijos žingsnį nuo mutacijos tikimybės svyravimo ribų:

$$\mu' = 3(1 - Q), \quad (9)$$

čia sėkmės tikimybė Q taip pat apskaičiuojama pagal formulę (7). Iš čia galima apskaičiuoti ir tikimybę mutacijos žingsniui padidėti, t. y.:

$$P_s^+ = 1 - \frac{\kappa}{3}. \quad (10)$$

Šiame skyriuje atliekama empirinė pristatytų metodų lyginamoji analizė, optimizuojant įvairaus sudėtingumo teorines funkcijas.

Penktame skyriuje pristatomas naujas mutacijos operatorius, pagrįstas regresine analize tarp *atsako kintamųjų* ir optimizacijos kintamųjų, t. y.:

$$y_i = f_i(x_1, x_2, \dots, x_n), \quad (11)$$

čia atsako kintamasis y_i yra arba tikslo funkcijos reikšmė, arba konkretaus apribojimo reikšmė. Kadangi evoliuciniai algoritmai generuoja optimizacijos kintamųjų ir atsako kintamųjų diskretines sekas, kurias galima pateikti 1 lentelėje, tai regresijos funkcija f_i nustatoma klasikiniiais metodais.

1 lentelė. *Atsako ir optimizacijos kintamųjų sekų pavyzdys*

y_i	x_1	x_2	...	x_n
y_{i1}	x_{11}	x_{21}	...	x_{n1}
\vdots	\vdots	\vdots	\vdots	\vdots
y_{it}	x_{1t}	x_{2t}	...	x_{nt}

Šiame darbe ši funkcija atitiko tiesinę daugianarę p -tosios eilės regresijos lygtį, turinčią tokią formą:

$$y_i = \beta_0 + \sum_{j=1}^n \sum_{k=1}^p \beta_{jk} x_j^k + \varepsilon, \quad (12)$$


čia n – optimizacijos kintamųjų skaičius; p – regresijos lygties laipsnis, β_i – regresijos koeficientai; ε – regresijos paklaida. Regresijos koeficientai nustatomi minimizuojant kvadratinio nuokrypio reikšmę. Toliau iš gautos regresijos lygties eliminuojami tie kintamieji, kurie neturi esminės įtakos atitinkamam atsakui. Šiam tikslui taikomas klasikinis metodas – *atvirkštinė eliminacijos procedūra*. Taip supaprastinta regresijos lygtis, skaitiškai skaičiuojant dalines išvestines pagal optimizacijos kintamuosius, leido rasti dalinius koreliacijos koeficientus tarp atsako kintamųjų ir kiekvieno optimizacijos kintamojo. Toliau kiekvieno koreliuoto optimizacijos kintamojo mutacija vykdoma pagal tokią schemą:

$$\max y_i : \begin{cases} + & : \rho_{ij}(x_j) > 0, \\ - & : \rho_{ij}(x_j) < 0, \end{cases} \quad (13)$$

$$\min y_i : \begin{cases} - & : \rho_{ij}(x_j) > 0, \\ + & : \rho_{ij}(x_j) < 0, \end{cases} \quad (14)$$

jį parodo, ar optimizacijos kintamasis x_j yra didinamas („+“), ar mažinamas („-“), kai atsakas y_i yra atitinkamai maksimizuojamas arba minimizuojamas. Pavyzdžiui, jeigu turime minimizacijos uždavinį, o atsakas y_i yra tikslo funkcija, tai optimizacijos kintamasis x_j yra didinamas, jeigu dalinis koreliacijos koeficientas ρ_{ij} tarp tikslo funkcijos ir šio optimizacijos kintamojo yra neigiamas.

Ši mutacijos schema algoritmą sparčiai nukreipia leistinosios aibės ribos link, kai mutuojami tie optimizacijos kintamieji, kurie yra koreliuoti su tikslo funkcija. Paieška nukreipiama iš neleistinosios aibės (tai įvyksta, kai pažeisti apribojimai), kai mutuojami tie optimizacijos kintamieji, kurie koreliuoti su sulaužytais apribojimais.



6 pav. Paieškos nukreipimas leistinosios aibės ribų link. Paveiksle pateiktas dvimatis optimizavimo uždavinys su dviem netiesiniais apribojimais g_1 ir g_2

Pavyzdžiui, 6 pav. taškai 1–4 yra leistinojoje aibėje, todėl mutacijos vektoriai nukreipti uždavinio optimumo link. O populiacijos taškai 5–9 yra už leistinosios aibės ribų, todėl mutacijos vektorių kryptys yra skaičiuojamos

atitinkamų sulaužytų apribojimų atžvilgiu. Pažymėtina, jog mutacijos vektorių kryptys standartiniuose evoliuciniuose algoritmuose nustatomos atsitiktiniu būdu. Tai yra šių metodų privalumas (pvz., platesnis pritaikymas) ir trūkumas (pvz., lėtas konvergavimas).

Šiame skyriuje taip pat atliekama empirinė pristatytų metodų lyginamoji analizė, optimizuojant įvairaus sudėtingumo teorines funkcijas.


Šeštame skyriuje pristatomas naujas stochastinis algoritmas, kuris pavadintas *sferiniu stochastiniu algoritmu*. Jis taip vadinamas dėl to, jog optimumo paieška atliekama sferoje, kuri n -matėje erdvėje tampa hipersfera. Algoritmas skirtas tik uždaviniams su apribojimais spręsti, o pagrindinė algoritmo idėja – pagrindinė algoritmo idėja – nagrinėti leistinosios aibės ribas, o čia inžinerinėje praktikoje dažniausiai ir yra optimalus uždavinio sprendimas.

Uždavinio apribojimų paieška vyksta naudojant vadinamuosius pozicijos vektorius. Pozicijos vektorius \vec{L} priskiriamas kiekvienam paieškos aibės taškui, o vektoriaus komponentių skaičius atitinka apribojimų skaičių m . Pozicijos vektoriaus i -toji komponentė apskaičiuojama pagal šią formulę:

$$L_i = \frac{|c_i(\vec{x})|}{c_i(\vec{x})}, \quad (15)$$

čia L_i – i -toji pozicijos vektoriaus komponentė, atitinkanti apribojimo c_i reikšmę. Sferos centras visada atitinka geriausią rastą tašką, o sferos spindulys apskaičiuojamas kaip Euclido atstumas tarp sferos centro ir taško, kuris turi labiausiai priešingą pozicijos vektorius. Kitaip sakant, jeigu centro taško pozicijos vektorius yra $\{-1, -1\}$, tai labiausiai jam priešingas taškas yra toks, kurio pozicijos vektorius turės visas priešingas komponentes, t. y. $\{1, 1\}$. 7 a pav. parodyta sferos spindulio apskaičiavimo taisyklė esant dviem taškų poroms su labiausiai priešingais pozicijos vektoriais. Čia pozicijos vektoriai pateikti skliausteliuose.

Optimizuojant visi taškai, kurių apskaičiuota vertės funkcija (1) ir pozicijos vektoriai (16), saugomi duomenų bazėje. Taškai, reikalingi naujos sferos spinduliui skaičiuoti, išrenkami iš šios duomenų bazės su tikimybe, kuri proporcinga kiekvieno taško vertės funkcijos reikšmei. Tokiu būdu taškai, turintys geresnes vertės funkcijos reikšmes, formuoja būsimą paieškos lauką – sferą, kuri tikėtina yra mažesnė už prieš tai buvusią (žr. 7 b pav.).



7 pav. Sferinė paieška: a) sferinio algoritmo sprendimų aibės apribojimas sfera; b) algoritmo konvergavimas mažėjant sferai ir centro taškui C_1 , artėjant prie optimalaus sprendimo. Paveiksluose pateiktas dvimatis optimizacijos uždavinys su dviem tiesiniais apribojimais g_1 ir g_2


Toliau sprendimo paieška atliekama generuojant atsitiktinius taškus sferos viduje, o kitos sferos spinduliai užtikrintai mažėja, jei paieškos aibės dalis centro taško kaimynystėje ištiriama greičiau, negu perkėlimas pačio centro taško.

Antra disertacijos dalis prasideda **septintu skyriumi**, kuriame sprendžiamas pirmas praktinis uždavinys. Optimizacijos objektas yra plieninis „Ducati“ motociklo rėmas, kuris turi būti palengvintas. 8 pav. pateiktas rėmo modelis su kraštinėmis sąlygomis.

Optimizacijos uždavinys formuluojamas taip: sumažinti rėmo masę neviršijus didžiausių leistinųjų įtempių bei išlaikant pradinį rėmo standumą sukimui tarp rėmo vairo vamzdžio ir galinės rėmo šakės. Uždavinį sudarė 30 optimizacijos kintamųjų, kurie yra rėmo vamzdelių skerspjūvių matmenys: vidinis skersmuo ir sienelės storis. Uždaviniui spręsti buvo taikyti keturi stochastiniai algoritmai:

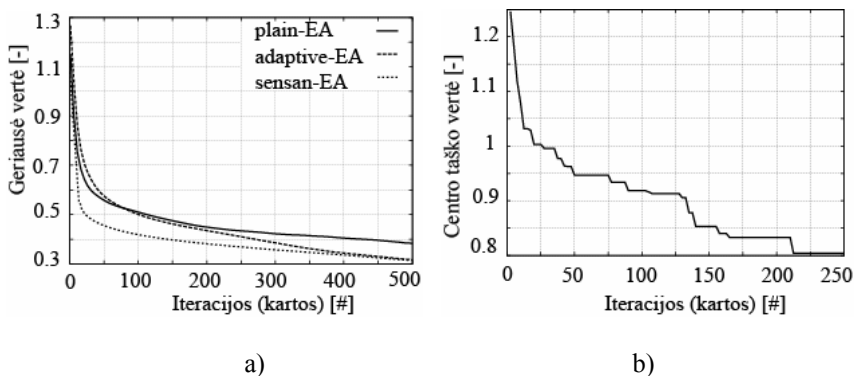
- Standartinis evoliucinis algoritmas, pažymėtas *plain-EA*, kuris taikytas palyginimui.
- Evoliucinis algoritmas su mutacijos prisitaikymo prie vertės funkcijos paviršiaus koncepcija (žr. ketvirtą skyrių), pažymėtas *adaptive-EA*.

- Evoliucinis algoritmas su mutacijos operatoriumi, pagrįstu regresijos analize, arba statistine jautrumo analize (žr. penktą skyrių), pažymėtas *sensan-EA*.
- Sferinis stochastinis algoritmas (žr. šeštą skyrių), pažymėtas *sphere-SA*.



8 pav. „Ducati“ rėmo modelis su kraštinėmis sąlygomis

Algoritmų konvergavimo kreivės parodytos 9 pav. Čia matome akivaizdų evoliucinių algoritmų pranašumą, palyginti su sferiniu algoritmu.




9 pav. Vertės funkcijos reikšmės: a) evoliucinių ir b) sferinio algoritmų, minimizuojant „Ducati“ rėmo masę

2 lentelė. „Ducati“ rėmo santykinis palengvinimas taikytais algoritmais


Algoritmas	Masės sumažėjimas [%]
Plain-EA	19,3
Adaptive-EA	17,6
Sensan-EA	21,7
Sphere-SA	10,9

10 pav. rodomas geriausias rėmo sprendimas, rastas *sensan-EA* algoritmu (žr. 2 lentelę). Palyginti su originalia rėmo konstrukcija, rėmo svoris sumažėjo 21,7 %.




10 pav. Geriausias „Ducati“ rėmo sprendimas

Aštuntame skyriuje rodomas kitas tezės metodų taikymo atvejis. Čia sprendžiamas kuro elemento (žr. 11 pav.) galinės plokštelės skerspjūvio topologijos optimizavimo uždavinys. 12 pav. parodytas plokštelės ketvirtis, kadangi ji turi dvi tarpusavio statmenas simetrijos plokštumas. Plokštelė yra veikiamą slėgio p_s iš apačios ir varžto gniuždymo jėgos iš viršaus. Optimizacijos uždavinys formuluojamas taip: minimizuoti plokštelės masę neviršijant leistinųjų didžiausių įtempių. Uždavinį sudarė 30 optimizacijos kintamųjų, kurie yra plokštelės skerspjūvio briaunų išdėstymas ir storiai, bei plokštelės pagrindo ir viršaus storiai.




11 pav. Principinė kuro elemento surinkimo schema




12 pav. Kuro elemento galinės plokštelės ketvirtis

Uždaviniui spręsti taikyti tie patys keturi stochastiniai algoritmai, kaip ir pirmame uždavinyje (žr. septintą skyrių), t. y.: *plain-EA*, *adaptive-EA*, *sensan-EA* ir *sphere-SA*. 13 pav. parodytos algoritmų konvergavimo kreivės. 14 pav. pateiktas geriausias optimizacijos sprendimas vėl rastas su *sensan-EA* algoritmu. Kaip parodyta 3 lentelėje, palyginti su originalia plokštelės konstrukcija, jos masė sumažėjo 43,8 %.



a)




b)

13 pav. Vertės funkcijos reikšmės: a) evoliucinių ir b) sferinio algoritmu, minimizuojant kuro elemento galinės plokštelės masę

3 lentelė. Kuro elemento galinės plokštelės santykinis palengvinimas taikytais algoritmais

Algoritmas	Masės sumažėjimas [%]
Plain-EA	40,0
Adaptive-EA	42,5
Sensan-EA	43,8
Sphere-SA	36,3



14 pav. Geriausias kuro elemento galinės plokštelės sprendimas

Nepaisant to, jog ir šiame taikomajame uždavinyje *sensan-EA* algoritmas rado geriausią sprendimą, *adaptive-EA* greičiausiai konvergavo optimalaus sprendimo link (žr. 13 a pav.) ir sumažino plokštelės masę 42,5 %, tai yra tos pačios eilės (skirtumas < 3 %) kaip ir *sensan-EA* algoritmo. Todėl šiam topologijos optimizacijos uždaviniui teigiama, jog geriausiai tinka *adaptive-EA*, t. y. evoliuciniai algoritmai su pasiūlytu mutacijos prisitaikymo būdu.

BENDROSIOS IŠVADOS

- Disertacijoje pristatyti keturi originalūs stochastinės paieškos metodai, kurie taikomi mechaninių sistemų elementų geometrijai optimizuoti. Pateikta darbo motyvacija ir atlikta literatūros apžvalga pagrindžia atliktų tyrimų aktualumą.
- Pirmasis metodas skirtas vertės funkcijos paviršiaus analizei. Jis grindžiamas geriausio populiacijos taško vertės funkcijos reikšmės dažnio matavimu. Geriausios vertės dažnis gali atspindėti vertės funkcijos plokštumą, daugiaoptimalumą ir nuolydį (pakilą) lokalaus optimumo link. Metodas taikomas tik populiaciniams stochastiniams algoritmams.
- Geriausio populiacijos taško dažnis leido sukurti originalią mutacijos tikimybės adaptacijos schemą evoliuciniams algoritmams. Čia mutacijos tikimybė ir mutacijos žingsnis tiesiogiai proporcingi geriausio taško vertės dažniui. Empiriniai tyrimai parodė, jog evoliuciniai algoritmai su pasiūlyta mutacijos adaptacijos schema turi kur kas geresnių konvergavimo savybių negu lyginamasis standartinis evoliucinis algoritmas.
- Trečiasis metodas – statistine jautrumo analize pagrįstas mutacijos operatorius evoliuciniams algoritmams. Čia mutacijos operatorius daugiausia mutuoja (naudojant pasiūlytą schemą) tik tuos optimizacijos kintamuosius, kurie yra koreliuoti su tikslo ar apribojimo funkcijos reikšmėmis. Įvykus šiai mutacijai evoliucinis algoritmas yra lengvai nukreipiamas leistinosios paieškos aibės ribų link, kur dažniausiai yra optimalūs inžinerinių uždavinių sprendimai. Sukurtas mutacijos operatorius leidžia sparčiai nukreipti paiešką iš neleistinųjų aibių, kai didžioji populiacijos dalis yra sulaužiusi uždavinio apribojimus. Empiriniai tyrimai parodė, jog šis metodas paspartina evoliucinių algoritmų konvergavimą optimumo link.
- Darbe pristatytas sferinis stochastinis algoritmas, skirtas uždaviniams su apribojimais spręsti. Algoritmas yra ypač efektyvus, kai optimalus duotojo uždavinio sprendimas yra ties tikslo ir apribojimų funkcijų sankirtos vieta.

Empiriniai tyrimai parodė, jog metodo efektyvumas yra atvirksčiai proporcingas apribojimų skaičiui.

- Sprendžiant abu praktinius uždavinius, geriausius rezultatus parodė evoliucinis algoritmas su statistine jautrumo analize pagrįsta mutacija. Tačiau algoritmo konvergavimo savybės buvo pranašesnės tik sprendžiant formos optimizacijos uždavinį – plieninio „Ducati“ motociklo rėmo palengvinimo uždavinį. Pagrindinė priežastis yra ta, jog formos optimizavimo uždaviniai dažniausiai yra tolydūs ir iškilūs, todėl algoritmo gebėjimas didinti konvergavimo greitį užtikrina jo efektyvumą. Išsprendus optimizacijos uždavinį, motociklo rėmas palengvėjo 21,7 % nuo pradinės masės.
- Evoliucinis algoritmas su mutacijos adaptacija parodė geriausias konvergavimo savybes sprendžiant topologijos optimizacijos uždavinį – kuro elemento galinės plokštelės palengvinimo uždavinį. Šis algoritmas čia buvo efektyviausias, nes topologijos optimizacijos uždaviniai, priešingai negu formos optimizacijos uždaviniai, paprastai yra netolydūs ir neiškilūs. Todėl algoritmo gebėjimas reguliuoti populiacijos paplitimą – įvairumą užtikrina algoritmo tinkamumą tokiems uždaviniams spręsti.
- Sferinis stochastinis algoritmas atsiliko nuo visų naudotų evoliucinių algoritmų, nes nesugebėjo palikti lokalaus optimumo arba reikalavo daug iteracijų centro taškui perkelti. Šį metodą reikia tirti toliau.

Trumpos žinios apie autorių. Romanas Puiša gimė 1976 m. lapkričio 28 d. Vilniuje. 1999 m. įgijo mechanikos inžinerijos bakalauro laipsnį, o 2001 m. – mechanikos inžinerijos magistro laipsnį Vilniaus Gedimino technikos universiteto Mechanikos fakultete. 1998–2002 m. dirbo privačioje firmoje „Čeli automatizuoto projektavimo sistemos“ UAB⁹ inžinerinio projektavimo sistemų programuotoju. 2001–2005 m. – Vilniaus Gedimino technikos universiteto doktorantas. Romanas Puiša 2002–2003 m. ir 2004–2005 m. vykdė mokslinius bendradarbiavimo projektus Šveicarijos federaliniame technologijos institute Ciuriche.

⁹ <http://www.cadteam.lt>

THE ADAPTIVE STOCHASTIC ALGORITHMS FOR STRUCTURE OPTIMISATION OF MECHANICAL PARTS

Summary

The current thesis undertakes a task to contribute to the continuous development of numerical optimisation methods which are of world-wide interest. The work presents four new ideas for stochastic algorithms addressed to the structural optimisation of mechanical assemblies and their parts. Since structure optimisation problems encountered in mechanical engineering are usually highly nonlinear, nosy, and discrete, stochastic algorithms represent reasonable optimisation methods for them. This evidence is justified by many successful applications of stochastic algorithms (e.g. evolutionary algorithms) on those mechanical engineering problems, where deterministic methods (e.g. gradient methods) are hardly applicable.

Mechanical design optimisation requires parameterising a structure and applying a chosen optimisation method. Nowadays the geometry of a mechanical structure is modelled by a computer-aided design (CAD) software. Such software usually allows to create 3-dimensional component-based models which are described by parameters defined by an engineer. Further on a mechanical model undergoes the finite element analysis allowing to simulate the mechanical behaviour of the structure. Thus, the modelling aims at defining optimisation variables, while the simulation gives the estimation of the model having certain optimisation variable values. These two mechanical design stages, the modelling and the simulation, are the prerequisites for parameterisation and optimisation methods. The current thesis addresses the further development of optimisation methods only and their approbation on structure optimisation problems.

Thesis Objective. The thesis objective is to develop original mechanical structure optimisation methods based on evolutionary algorithms and the plain Monte Carlo search. The stated objective is achieved through the following three main steps:

- By developing new convergence-improving approaches for evolutionary algorithms.
- By presenting a new stochastic optimisation algorithm applied to constrained engineering problems.
- By applying the developed methods to real structure optimisation problems and comparing them with a plain evolutionary algorithm.

Research Methodology. The implementation and the numerical analysis of the presented researches were performed by EO¹⁰ (evolving objects) which is a templates-based and ANSI-C++ compliant evolutionary computation library. The library contains classes for most popular algorithms of the evolutionary computation, that is: genetic algorithms, evolutionary strategies, the genetic programming, and the evolutionary programming. For the graphical analysis of numerical results the GNUPLOT¹¹ software was used. This software is freely distributed under Linux operation systems.

The finite element (FE) analysis of test mechanical structures was performed by FeLyX¹² FE library and the CATIA¹³ integrated FE solver. The geometrical models of mechanical structures were built by ANSYS¹⁴ integrated geometrical modeller and the CATIA CAD environment.

Practical Value. An application of presented ideas in engineering practice allows to efficiently solve complex structure optimisation problems, since:

- Evolutionary algorithms with enhanced convergence behaviour require less function evaluations until an optimal solution is found. That results in a shortened product development cycle.
- The alternative stochastic algorithm suggests a new method for solving theoretical and practical problems. The underlying idea of this method is also to minimise function evaluations while optimising.
- The developed optimisation methods are distributed as a software package which can be easy integrated in popular mechanical design systems (e.g. CATIA) and used in every day engineering work.

Scientific Novelty. The following scientific novelty of the work is emphasised:

- The original objective function landscape analysis method, which has been developed in this work, allows to predict the algorithmic efficiency during the optimisation. This method – a fundamental concept giving a base for solving some crucial stochastic-search related problems such as the search adaptation to the objective function landscape. This adaptation problem has been solved by developing a new mutation adaptation scheme for evolutionary algorithms.

¹⁰ <http://eodev.sourceforge.net>

¹¹ <http://www.gnuplot.info>

¹² <http://felyx.sourceforge.net>

¹³ <http://www.catia.com>

¹⁴ <http://www.ansys.com>

- The thesis also presents a new promising algorithmic convergence enhancing method for evolutionary algorithms. This method – the statistical sensitivity analysis based mutation operator makes the search by evolutionary algorithm significantly robust and faster (tested for nonlinear programming) compared to standard evolutionary algorithms.
- The developed new alternative stochastic algorithm allows to efficiently solve linear and nonlinear programming problems where a theoretical optimum locates at or near the intersection between the objective and constraint functions.

Author’s Publications. In Journals:

1. Puisa, R. and Pauza, V. Adaptive design CAD systems. *Mechanika*, KTU, 2(28):60-67, 2001.
2. Puisa, R. Solving 3D constraint problem in assembling of semi-adaptive parts. *Mechanika*, KTU, 3(35):40-48, 2002.
3. Puisa, R. and Vekteris, V. Contextual CAD-Entity based parameterization in Structure Optimization. *WSEAS Transactions on Circuits and Systems*, 3(8):1647-1652, 2004.
4. Puisa, R. and Belevicius, R. Grading the PVC material by solving a static inverse problem with genetic algorithm. *Mechanika*, KTU, 2(52):11-16, 2005.
5. König, O., Puisa, R., Wintermantel M., and Ermanni P. CAD-entity based evolutionary design optimization. *Computer-Aided Design*. (Accepted, preprint).

In Conference Proceedings:

1. Puisa, R. and Vekteris, V. Conception of Adaptive Design. In: 1st International Meeting of Science and Technology of Design. Senses and Sensibility in Technology – Linking Tradition to Innovation through Design. Lisbon, Portugal, 2003, p 110-115.
2. Puisa, R. and Vekteris, V. Contextual CAD-entity based parameterization. In: Proceedings of 4th International Congress on Mechanical Engineering Technologies. The Scientific-Technical Union of Mechanical Engineering, Bulgaria, 2004, p 175-178.
3. Liederman, Ch., Puisa, R., and Ermanni, P. Smart Instantiation Objects in Aircraft Pre-Design. In: The 6th International Conference on Computer Aided Industrial Design and Conceptual Design. The Netherlands, 2005, p 442-447.

Oral Presentations at Conferences:

1. Puisa, R. Adaptive geometry in mechanical design by CAD systems. In Mechanics, International Conference, KTU, Lithuania, 4-5th April 2002.
2. Puiša, R. Volumentinės pompos peristaltinio mechanizmo optimizacija. Konferencijoje: Mechaninės sistemos ir medžiagos, Mechanikos fakultetas, VGTU, Lithuania, 31st October 2003.

The author together with co-authors has also submitted three dissertation research-based publications to the prestigious journals: *Evolutionary Computation* and *Journal on Optimization*.

Propositions for Thesis Defence. The defence propositions are as follows:

- The thesis presents four original ideas which enrich the class of stochastic optimisation methods.
- The first idea – method stands for a fundamental concept proposing a new view at the objective-function landscape analysis issue.
- The second method is a practical implementation of the first idea. This method applies to evolutionary algorithms and allows to solve the adaptation to the fitness function landscape issue. As a result, the optimization process becomes more efficient.
- The third method presents a new mutation operator for evolutionary algorithms. The theoretical and empirical analysis of the method supports its reasonability.
- The fourth method – a new stochastic algorithm aiming at minimizing function evaluations by searching for solutions near the feasibility borders, where optima are expected for some class of engineering problems.
- The application of the developed methods to real machine design problems proved their efficiency compared to standard stochastic optimization algorithms.

Thesis Outline. This dissertation results from the collaborative researches between Vilnius Gediminas Technical University and Swiss Federal Institute of Technology Zurich. The researches were supported by Swiss Baltic Net¹⁵ programme which represents the Gebert Rűf foundation for Baltic States (project grant no. P-004/04/29300.022).

After the introductory chapter 1, the thesis continues from chapter 2 where the relevant literature is reviewed and discussed. Then two main thesis parts

¹⁵ <http://www.swissbaltic.net>

follow. Part I presents four new ideas in terms of stochastic algorithms and discusses their theoretical performance issue. Thus, chapter 3 introduces a new approach for the fitness landscape analysis. This approach aims at predicting the runtime efficiency of evolutionary algorithms through the calculation of higher-order statistical moments, namely the skewness and the kurtosis, and the use of a new proposed statistic – *the best fitness frequency*. The underlying idea of this statistical analysis is based on two hypotheses: (1) a population, considered as a distribution of fitness values, varies over run-time by changing its shape, and (2) such a variance of the *fitness-distribution shape* reflects fitness landscape regions. The optimisation results performed on some theoretical test functions support the stated hypotheses. The following chapter 4 presents a new mutation adaptation approach for evolutionary algorithms. This approach includes the mutation rate adaptation and mutation step adaptation issues. The development of this adaptation approach was motivated by the fitness landscape analysis concept presented in chapter 3 which is suitable for the mutation adaptation. Chapter 5 presents another original idea for evolutionary algorithms. Here a new mutation operator aimed at constrained optimisation problems is introduced. The new mutation operator is based on the statistical sensitivity analysis (SSA) and applied for response variables such as the objective function and imposed constraints. The independent variables, or input variables, are genes of an individual. The goal of SSA is to find those genes which influence a certain response variable, since the only some genes may have an actual correlation with a certain response variable. Then the mutation operator tends to mutate only those found correlated input variables and navigates the search towards the feasibility borders. The performed test cases show the reasonability of the mutation operator. The last chapter 6 of part I manifests a new stochastic algorithm for the constrained optimisation. The algorithm is named *spherical stochastic algorithm* since the search is performed in a sphere, which in the n-dimensional space becomes a hyper-sphere. The centre point of the hyper-sphere always represents the best point found so far while the radius is an Euclidean distance between the centre point and farthest selected infeasible point. Consequently the search space always includes feasible and infeasible regions. Chapter 6 also discusses the theoretical convergence aspect of the spherical stochastic algorithm by performing some theoretical test cases.

In part II the presented ideas are tested by applying them for solving two practical problems. Thus, chapter 7 demonstrates the mass minimisation of Ducati motorbike frame subject to stiffness and stress constraints. In chapter 8 the CAD-based topology optimisation of an end-plate of a fuel cell is performed. For these two applications four stochastic algorithms were used: (1)

a plain evolutionary algorithm which was derived from genetic algorithms and used for a comparison purpose, (2) the plain evolutionary algorithm with the mutation adaptation introduced in chapter 4, (3) the plain evolutionary algorithm with the statistical sensitivity analysis based mutation operator presented in chapter 5, and the spherical stochastic algorithm laid out in chapter 6.

General Conclusions. The following conclusions are drawn:

- The thesis has introduced four original approaches for stochastic algorithms addressed to the structure optimisation of mechanical parts. The given thesis motivation and the literature review justify the need of the accomplished researches.
- The first approach proposes a new point of view on the fitness landscape analysis issue. The approach bases on the frequency analysis of the best-point fitness value in the population. The best fitness frequency reflects the flatness, multimodality, and unimodality of the fitness landscape. This approach is applicable to population-based stochastic algorithms only.
- Based on the best fitness frequency measure the new mutation adaptation concept for evolutionary algorithms has been introduced. Here the mutation probability and the mutation step are proportional to the best fitness frequency. The empirical convergence analysis shows that evolutionary algorithms with the new mutation adaptation approach have superior convergence behaviour than comparative standard evolutionary algorithms.
- The third presented idea introduced the new mutation operator bases on the regression between optimisation variables – genes and a response variable which is either the objective or the constraint function. The mutation operator applies in evolutionary algorithms and mutates mostly those genes which are correlated to an actual response variable. As a result, a population of individuals can be navigated towards feasibility border where optimal solutions are supposed to be located. Since the only linear multiple regression was used, the obtained regression model is rather approximate, although the theoretical analysis showed that such a regression model is satisfactory.
- The fourth promising idea of the thesis is the spherical stochastic algorithm. The algorithm is named spherical since it performs the search in a sphere, or hypersphere, with the centre representing the best point found so far and the radius shrinking with generations. The algorithm applies only for constrained optimisation problems, although it loses its efficiency with growing constraint number, as the theoretical analysis indicates.

- The first application – a sizing optimisation problem showed the superior performance of the evolutionary algorithm with the biased mutation operator or the mutation based on regression between response and optimization variables. The optimisation resulted in 21,7% in the mass reduction, compared to the initial design.
- The second application – a CAD-based topology optimisation problem where the evolutionary algorithm with the mutation adaptation approaches showed the best convergence behaviour resulting in 42,5% in the mass reduction, compared to the initial design.
- Therefore, for sizing optimisation problems, which are supposed to be often continuous, evolutionary algorithms with the regression-based mutation operator should be used. Consequently, for problems such as topology optimisation problems, which are expected to be highly discontinuous, evolutionary algorithm with the presented mutation adaptation approaches should be applied.
- In both applications the spherical stochastic algorithm did not cope to escape from local optima or was too slow to investigate infeasibility border within predefined number of generations. Therefore the spherical algorithm needs being further investigated by solving the convergence speed and robustness drawbacks.

Shortly about the author. Romanas Puiša was born in Vilnius on 28th of November 1976. In 1999 graduated from Faculty of Mechanics of Vilnius Gediminas Technical University as a bachelor and in 2001 as a Master in Mechanical Engineering. During 1998-2002 had worked in the private company „Čeli automatizuoto projektavimo sistemas“ Ltd.¹⁶ as a developer of computer aided design software. During 2001-2005 had been a Ph.D. student at Faculty of Mechanics of Vilnius Gediminas Technical University. During 2002-2003 and 2004-2005 had participated in collaborative projects in Swiss Federal Institute of Technology Zurich.

¹⁶ <http://www.cadteam.lt>

Romanas Puiša

**ADAPTYVIEJI STOCHASTINIAI ALGORITMAI
MECHANINIŲ SISTEMŲ ELEMENTAMS OPTIMIZUOTI**

**Daktaro disertacijos santrauka
Technologijos mokslai, mechanikos inžinerija (09T)**

SL 136. 2005 09 13. 2,0 apsk. leid. 1. Tiražas 100 egz.

Leido Vilniaus Gedimino technikos universiteto

leidykla „Technika“, Saulėtekio al. 11, LT-10223 Vilnius-40

Spausdino UAB „Biznio mašinų kompanija“, Gedimino pr. 60,
LT-01110 Vilnius