

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**Metódy sedlového bodu na riešenie
úloh konvexného programovania**

DIPLOMOVÁ PRÁCA

BRATISLAVA 2012

Bc. TOMÁŠ ROSENBERG

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY
KATEDRA APLIKOVANEJ MATEMATIKY A ŠTATISTIKY



**Metódy sedlového bodu na riešenie
úloh konvexného programovania**

DIPLOMOVÁ PRÁCA

Študijný program : Ekonomická a finančná matematika

Študijný odbor : 1114 Aplikovaná matematika

Skoliteľ : doc. RNDr. Milan Hamala, CSc.

BRATISLAVA 2012

Bc. TOMÁŠ ROSENBERG



ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Tomáš Rosenberg

Študijný program: ekonomická a finančná matematika (Jednooborové štúdium, magisterský II. st., denná forma)

Študijný odbor: 9.1.9. aplikovaná matematika

Typ záverečnej práce: diplomová

Jazyk záverečnej práce: slovenský

Názov: Metódy sedlového bodu na riešenie úloh konvexného programovania

Ciel: Metódy sedlového bodu na riešenie úloh konvexného programovania

Vedúci: doc. RNDr. Milan Hamala, CSc.

Katedra: FMFI.KAMŠ - Katedra aplikovanej matematiky a štatistiky

Dátum zadania: 13.01.2011

Dátum schválenia: 14.01.2011

prof. RNDr. Daniel Ševčovič, CSc.

garant študijného programu

.....
študent

.....
vedúci práce

Prehlásenie

Čestne prehlasujem, že som diplomovú prácu vypracoval samostatne s použitím uvedenej literatúry a s odbornou pomocou školiteľa.

Bratislava, 25. apríla 2012

.....
Bc. Tomáš Rosenberg

Podčakovanie

Na tomto mieste by som sa chcel srdečne podčakovať vedúcemu diplomovej práce doc. RNDr. Milanovi Hamalovi, CSc., za obrovské množstvo času, ktoré mi venoval a za jeho cenné rady, nápady, pripomienky a usmernenia, ktoré mi veľmi pomohli pri písaní tejto práce. Ďakujem taktiež svojej rodine a priateľom za trpezlivosť a podporu.

Abstrakt

ROSENBERG, Tomáš, Bc., Metódy sedlového bodu na riešenie úloh konvexného programovania

Univerzita Komenského v Bratislave, Fakulta matematiky, fyziky a informatiky, Katedra aplikovanej matematiky a štatistiky.

Vedúci diplomovej práce: doc. RNDr. Milan Hamala, CSc.

Diplomová práca, 2012.

V práci sa venujeme najmä metódam rozšírených Lagrangeových funkcií, ktoré sú jedným z nástrojov na riešenie úloh nelineárneho programovania. Ich podstatou je nahradíť riešenie danej úlohy postupnosťou úloh na voľnú optimalizáciu. Okrem klasickej metódy Hestenesa, Powella a Rockafellara bolo navrhnutých množstvo alternatívnych metód, vrátane techniky nelineárneho škálovania. V posledných dvadsiatich rokoch boli naviac navrhnuté postupy, ktoré v záverečnej fáze algoritmu nahradia minimalizáciu rozšírenej Lagrangeovej funkcie riešením špeciálnej sústavy rovníc. Výsledkom je asymptoticky vyššia rýchlosť konvergencie. Okrem študovania týchto postupov sa pokúsime aplikovať novú metódu založenú na komplementárnych funkciách. Naším hlavným cieľom je implementácia uvedených algoritmov a vykonanie numerických experimentov, na ktoré použijeme náhodne generované konvexné úlohy kvadratického programovania a vybranú množinu úloh z kolekcie CUTEr.

Kľúčové slová: nelineárne programovanie, rozšírené Lagrangeove funkcie, nelineárne škálovanie, primárno-duálny systém, Fischerova funkcia, numerické experimenty.

Abstract

ROSENBERG, Tomáš, Bc., Saddle point methods for solving convex optimization problems

Comenius University in Bratislava, Faculty of Mathematics, Physics and Informatics, Department of Applied Mathematics and Statistics.

Supervisor: doc. RNDr. Milan Hamala, CSc.

Master Thesis, 2012.

In this master thesis we study in particular the augmented Lagrangian methods, which represent one of the well-known approaches to solving constrained optimization problems. Their purpose is to replace the solving of a given problem by sequence of unconstrained optimization subproblems. Aside to the classic Powell-Hestenes-Rockafellar algorithm many other methods of this kind were proposed, notably of the nonlinear-rescalling framework. Also in the last two decades some special procedures were suggested, which replaced the unconstrained optimization by solving particular system of equations in the last phase of the main algorithm. This results in an asymptotically faster rate of convergence. In addition to studying these methods, we try to apply a new method based on complementarity-problem functions. Our major goal is to implement aforementioned algorithms and to perform numerical experiments on randomly generated convex quadratic programming problems and selected problems from the CUTER collection.

Keywords: nonlinear programming, augmented Lagrangian functions, nonlinear-rescalling, primal-dual system, Fischer function, numerical experiments.

Obsah

Úvod	1
Zoznam hlavných symbolov	3
1 Úvod do matematického programovania	4
1.1 Úloha s ohraničeniami v tvare rovníc	5
1.2 Úloha s ohraničeniami v tvare nerovníc	7
1.3 Úloha konvexného programovania a teória duality	11
1.3.1 Postačujúce podmienky optimality	12
1.3.2 Duálna úloha a teória duality	13
2 Metódy rozšírených Lagrangeových funkcií	16
2.1 Metóda Hestenesa a Powella pre úlohu s ohraničeniami v tvare rovníc	18
2.1.1 Iterácie multiplikátorov	23
2.2 Metóda Rockafellara pre úlohu s ohraničeniami v tvare nerovníc . . .	27
2.2.1 Odvodenie odhadu druhého rádu	31
2.3 Všeobecná penalizačná funkcia	34
2.3.1 Penalizačné funkcie pre úlohu (\mathcal{PR})	35
2.3.2 Penalizačné funkcie pre úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$	36
3 Nelineárne škálovanie a Fischerova metóda	41
3.1 Metóda nelineárneho škálovania	42
3.2 Primárno-duálna metóda Polyaka a Grivu	45
3.3 Vylepšená primárno-duálna schéma	49
3.4 Fischerova schéma	52

4 Numerické experimenty	57
4.1 Generátor úloh	57
4.2 Implementácie algoritmov	60
4.2.1 Rockafellarov algoritmus	60
4.2.2 Nelineárne škálovanie	62
4.2.3 Algorimus PDNRD Polyaka a Grivu	63
4.2.4 Fischerove algoritmy	64
4.3 Výsledky experimentov	65
4.3.1 Ilustračný príklad	67
4.3.2 Test č. 1: Vplyv rozmerov úlohy	67
4.3.3 Test č. 2: Zmena počtu ohraničení	69
4.3.4 Test č. 3: Zmena počtu aktívnych ohraničení	70
4.3.5 Test č. 4: Zmena počtu kvadratických ohraničení	71
4.3.6 Test č. 5: Zmena čísla podmienenosťi	73
4.3.7 Zbierka CUTER	74
Záver	75
Literatúra	77
Príloha	81
A. Newtonova minimalizačná metóda a vyhľadávanie na lúči	81
B. Výsledky testovania príkladov CUTER	84
C. Zdrojový kód	95

Úvod

Požiadavka optimalizácie je stále častejšie sa vyskytujúcim problémom v technickej a vedeckej praxi. Veľký úspech lineárneho programovania v polovici minulého storočia bol podnetom pre formuláciu a štúdium zložitejších modelov. Tento fakt bol podporený zisteniami z praxe, kde sa ukázalo, že lineárne modely niekedy nedokážu dostatočne dobre zachytiť podstatu problému a boli tak používané skôr ako východisko z núdze. Výsledkom bol vznik nelineárneho programovania, ktoré dnes nachádza široké praktické uplatnenie (napr. modelovanie chemických a fyzikálnych javov, optimálny výber portfólia, úlohy plánovania a optimálneho riadenia).

Jednou zo základných metód na riešenie nelineárnych optimalizačných úloh sú metódy rozšírených Lagrangeových funkcií, ktorých podstatou je nahradenie riešenia zložitej optimalizačnej úlohy postupnosťou riešení jednoduchších minimalizačných úloh s cieľom nájdenia sedlového bodu týchto funkcií. Spomínané metódy sú nástupcami penalizačných metód a odstraňujú niektoré ich nedostatky zavedením vektora Lagrangeových multiplikátorov. Ich vznik sa datuje do roku 1969, kedy bola Powellom [35] a nezávisle Hestenesom [22] uverejnená prvá metóda tohto druhu pre úlohy s ohraničeniami v tvare rovníc. Rockafellar [40] neskôr danú metódu rozšíril aj pre ohraničenia v tvare nerovníc a postupom času vzniklo mnoho rôznych tvarov rozšírených Lagrangeových funkcií [4]. Veľký teoretický aj praktický záujem o tieto metódy bol badateľný najmä v 70-tych a 80-tych rokoch 20. storočia, kde medzi popredných autorov tejto oblasti patril najmä Bertsekas [1]. V nasledujúcich rokoch sa pozornosť mierne vytratila a upriamila sa na metódy vnútorného bodu.

O čiastočný návrat rozšírených Lagrangeových funkcií sa postarali Polyak a Griva, ktorí v sérii článkov [30], [32], [33], [34] rozpracovali základy tzv. primárno-duálnej nelineárne škálovacej metódy. Tento prístup je založený na použití metódy špeciálnej rozšírenej Lagrangeovej funkcie a modifikácie jej záverečnej výpočtovej fázy. Polyak a Griva navrhli nahradieť minimalizáciu Lagrangeovej funkcie riešením tzv. primárno-

duálneho systému, čoho výsledkom je väčšia rýchlosť konvergencie. Do pozornosti sa dostáva aj alternatívna metodika, založená na transformácii KKT systému Fischerovou transformačnou funkciou [14].

Cieľom práce je oboznámiť sa s metódami sedlového bodu a ich algoritmickou realizáciou, implementovať tieto algoritmy a vykonať numerický experiment s cieľom ich vzájomného porovnania. Tieto ciele sú realizované v štyroch hlavných kapitolách.

V prvej kapitole uvádzame základné poznatky z teórie nelineárneho programovania.

V druhej kapitole sa venujeme teoretickému rozboru metód rozšírených Lagrangeových funkcií. Spomíname Powellovu-Hestenesovu metódu, z ktorej postupne odvodíme Rockafellarovu metódu a takisto uvedieme všeobecné triedy rozšírených Lagrangeových funkcií.

V tretej kapitole nadviažeme na výsledky druhej kapitoly a uvedieme primárno-duálnu nelineárne škálovaciu metódu Polyaka a Grivu a takisto Fischerovu metódu.

Štvrtú kapitolu venujeme numerickým experimentom. Spomenieme schematické implementácie testovaných algoritmov, spôsob generovania náhodných úloh konvexného bikvadratického programovania. Numerické testy vykonáme na spomínaných náhodne generovaných úlohách a takisto na vybraných úlohách zo štandardného testovanieho balíka CUTEr.

Nasleduje zoznam použitej literatúry, výsledky experimentov na CUTEr príkľa- doch a časť zdrojového kódu pre prostredie MATLAB. Úplný zdrojový kód je obsia- hnútý na priloženom médiu.

Zoznam hlavných symbolov

$\mathbf{A}, \mathbf{C}, \mathbf{D}$	matice
\mathbf{I}, \mathbf{I}_n	jednotková matica (dimenzie $n \times n$)
$\mathbf{x}, \mathbf{x}, \mathbf{y}, \mathbf{z}, \mathbf{u}, \mathbf{v}, \boldsymbol{\xi}, \boldsymbol{\mu}$	vektory (stĺpcové)
$\mathbf{A}^T, \mathbf{x}^T$	transponovaná matica k matici \mathbf{A} , transponovaný vektor k vektoru \mathbf{x} (výsledkom je riadkový vektor)
$\mathbf{x}^T \mathbf{y}$	skalárny súčin vektorov \mathbf{x}, \mathbf{y}
$\mathbf{y} \geq 0$	vektor, ktorého všetky zložky sú väčšie alebo rovné nule
$\mathbb{S}, \mathbb{M}, \mathbb{X}, \mathbb{Y}$	množiny
\mathbb{R}	množina reálnych čísel
$\mathbb{R}_n, \mathbb{R}_n^+, \mathbb{R}_n^{++}$	n -rozmerný Euklidovský priestor, jeho nezáporný, resp. kladný ortant
$f(\mathbf{x})$	reálna funkcia n -premenných $\mathbf{x} = (\mathbf{x}_1, \dots, \mathbf{x}_n)^T$
$\nabla f(\mathbf{x})$	gradient funkcie $f(\mathbf{x})$, t.j. stĺpcový vektor, ktorého zložky sú prvé parciálne derivácie funkcie $f(\mathbf{x})$, čiže $(\nabla f(\mathbf{x}))_i = \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}_i}$
$\nabla^2 f(\mathbf{x})$	Hessova matica funkcie $f(\mathbf{x})$, t.j. matica druhých parciálnych derivácií, $(\nabla^2 f(\mathbf{x}))_{ij} = \frac{\partial^2 f(\mathbf{x})}{\partial \mathbf{x}_i \partial \mathbf{x}_j}$
$F(\mathbf{x}) = (f_1(\mathbf{x}), \dots, f_m(\mathbf{x}))^T$	vektorová funkcia premennej \mathbf{x} , $F : \mathbb{X} \rightarrow \mathbb{R}^m$
$\nabla F(\mathbf{x})$	Jakobiho matica funkcie $F(\mathbf{x})$, t.j. matica, ktorej riadkami sú gradienty funkcií $f_i(\mathbf{x})$, pre i -ty riadok $\nabla F(\mathbf{x})$ platí $(\nabla F(\mathbf{x}))_i = \nabla f_i(\mathbf{x})^T$
$L(\mathbf{x}, \mathbf{u}, \mathbf{v}), \mathcal{L}(\mathbf{x}, \mathbf{y}, \mathbf{z})$	označenie pre klasickú, resp. rozšírenú Lagrangeovu funkciu
$\ \mathbf{x}\ $	norma vektora \mathbf{x} , najčastejšie $\ \mathbf{x}\ _2 = \sqrt{\mathbf{x}^T \mathbf{x}}$
$\text{diag}(\mathbf{x})$	diagonálna matica, ktorej diagonálu tvoria prvky vektora \mathbf{x}
$\text{rank}(\mathbf{A})$	hodnosť matice \mathbf{A} , t.j. počet jej lineárne nezávislých riadkov (stĺpcov)
$(\mathcal{PR}), (\mathcal{P}\mathcal{N}\mathcal{R}), \dots$	označenia úloh matematického programovania

Kapitola 1

Úvod do matematického programovania

Pod ľubovoľným problémom optimalizácie rozumieme výber „najlepšieho“ riešenia spomedzi všetkých dostupných riešení. Na určenie kvality týchto riešení používame *účelovú* funkciu, ktorú v závislosti od filozofie a podstaty problému minimalizujeme alebo maximalizujeme. Takýto problém môžeme zapísať ako

$$\begin{aligned} & \text{minimalizovať} && f(\boldsymbol{x}) \\ & \text{za podmienok} && \boldsymbol{x} \in \mathbb{M}, \end{aligned} \tag{1.1}$$

kde $f : \mathbb{X} \rightarrow \mathbb{R}$ je už spomínaná *účelová* funkcia, a množinu $\mathbb{M} \subset \mathbb{X}$ nazývame množinou *prípustných* riešení. Kedže maximalizácia funkcie f je ekvivalentná minimalizácii $-f$, na základe konvencie sa preto obmedzíme na úlohy formulované v uvedenom tvare. Vektor $\hat{\boldsymbol{x}}$ nazveme *lokálnym* minimom (*lokálnym* riešením) úlohy (1.1), ak existuje $\delta > 0$ také, že

$$f(\hat{\boldsymbol{x}}) \leq f(\boldsymbol{x}) \quad \forall \boldsymbol{x} \in \mathbb{M}, \|\hat{\boldsymbol{x}} - \boldsymbol{x}\| < \delta, \tag{1.2}$$

ostrým lokálnym minimom (*ostrým lokálnym* riešením), ak v (1.2) platí ostrá nerovnosť, a nakoniec *globálnym* minimom (*globálnym* riešením), ak

$$f(\hat{\boldsymbol{x}}) \leq f(\boldsymbol{x}) \quad \forall \boldsymbol{x} \in \mathbb{M}.$$

V prípade, že $\mathbb{M} = \mathbb{R}^n$, dostávame úlohu *voľnej* minimalizácie. Našim záujmom je však zaoberať sa problémami, kde $\mathbb{M} \subset \mathbb{R}^n$.

V celej práci budeme predpokladať nasledovné:

Predpoklad 1.1. *Množina optimálnych riešení*

$$\widehat{\mathbb{M}} = \{\hat{\mathbf{x}} \mid f(\hat{\mathbf{x}}) \leq f(\mathbf{x}), \forall \mathbf{x} \in \mathbb{M}\}$$

je neprázdna a ohraničená.

Z matematického hľadiska je zaujímavé popísať \mathbb{M} ako množinu všetkých bodov $\mathbf{x} \in \mathbb{X}$, ktoré spĺňajú nejakú sústavu rovníc a nerovníc, čiže

$$\mathbb{M} = \left\{ \mathbf{x} \in \mathbb{X} \mid \begin{array}{l} g_i(\mathbf{x}) \geq 0, \quad i = 1, \dots, m \\ h_j(\mathbf{x}) = 0, \quad j = 1, \dots, p \end{array} \right\},$$

pričom ohraničenia g_i, h_j sú reálne funkcie, $g_i : \mathbb{X} \rightarrow \mathbb{R}$ ($i = 1, \dots, m$), $h_j : \mathbb{X} \rightarrow \mathbb{R}$ ($i = 1, \dots, p$), a naviac o týchto funkciách, a takisto o funkcií f predpokladáme, že sú spojito diferencovateľné. Kvôli zjednodušeniu zápisov a úvah predpokladajme, že $\mathbb{X} = \mathbb{R}^n$. Dostávame sa tak ku klasickej formulácii úlohy *matematického programovania*.

V ďalšom texte sa budeme venovať variáciám tejto úlohy a sformulujeme niektoré základné tvrdenia o ich optimálnom riešení. Začneme úlohou, ktorej množina prípustných riešení \mathbb{M} je tvorená iba rovnicami (t.j. $m = 0$), a na základe výsledkov odvodených pre túto úlohu vyslovíme ich ekvivalenty aj pre úlohu s ohraničeniami v tvare nerovníc ($p = 0$).

1.1 Úloha s ohraničeniami v tvare rovníc

Uvažujme úlohu matematického programovania v tvare

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && h_j(\mathbf{x}) = 0, \quad j = 1, \dots, p. \end{aligned} \tag{PR}$$

Nech $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $h_j : \mathbb{R}^n \rightarrow \mathbb{R}$ ($j = 1, \dots, p$), a takisto $f \in C^1, h_j \in C^1$ pre všetky j . Pre zjednodušenie niektorých zápisov označme

$$h(\mathbf{x}) = (h_1(\mathbf{x}), \dots, h_p(\mathbf{x}))^\top,$$

potom $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$, a predpokladajme, že $p \leq n$. Pripomeňme, že symbolom $\nabla h(\mathbf{x})$ označujeme Jakobiho maticu funkcie h .

Množina prípustných riešení \mathbb{M} úlohy (PR) má tvar

$$\mathbb{M} = \{\mathbf{x} \mid h(\mathbf{x}) = 0\}.$$

Pred vyslovením základného tvrdenia (Lagrange, 1760) o nutných podmienkach optimálneho riešenia úlohy (\mathcal{PR}) uvedieme definíciu *regulárneho* bodu, ktorú budeme potrebovať pri jej vyslovení.

Definícia 1.1. Bod $\hat{\mathbf{x}} \in \mathbb{M}$ nazývame regulárnym, ak sú gradienty ohraničení $\nabla h_1(\hat{\mathbf{x}}), \dots, \nabla h_p(\hat{\mathbf{x}})$ lineárne nezávislé, t. j.

$$\text{rank}(\nabla h(\hat{\mathbf{x}})) = p.$$

Teraz môžeme pristúpiť k vysloveniu tvrdenia.

Veta 1.1. Nech $\hat{\mathbf{x}}$ je lokálnym riešením úlohy (\mathcal{PR}) a takisto regulárnym bodom. Potom existuje (jednoznačne určený) vektor Lagrangeových multiplikátorov $\hat{\mathbf{v}} = (\hat{\mathbf{v}}_1, \dots, \hat{\mathbf{v}}_p)^T$ taký, že platí

$$\nabla f(\hat{\mathbf{x}}) + \sum_{j=1}^p \hat{\mathbf{v}}_j \nabla h_j(\hat{\mathbf{x}}) = 0, \quad (1.3)$$

$$h(\hat{\mathbf{x}}) = 0. \quad (1.4)$$

Ak naviac $f \in C^2$, $h \in C^2$, potom platí

$$\boldsymbol{\omega}^T \left[\nabla^2 f(\hat{\mathbf{x}}) + \sum_{j=1}^p \hat{\mathbf{v}}_j \nabla^2 h_j(\hat{\mathbf{x}}) \right] \boldsymbol{\omega} \geq 0 \quad (1.5)$$

pre všetky $\boldsymbol{\omega}$ také, že $\nabla h(\hat{\mathbf{x}})\boldsymbol{\omega} = 0$.

DÔKAZ: Je možné nájsť v [3], str. 281-283, prípadne [24], str. 327. \square

Sústavu $n + p$ rovníc (1.3), (1.4) zvyčajne zapisujeme pomocou klasickej *Lagrangeovej funkcie*, ktorú definujeme predpisom

$$L(\mathbf{x}, \mathbf{v}) = f(\mathbf{x}) + \sum_{j=1}^p \mathbf{v}_j h_j(\mathbf{x}) = f(\mathbf{x}) + h(\mathbf{x})^T \mathbf{v}, \quad (1.6)$$

kde $L : \mathbb{R}^n \times \mathbb{R}^p \rightarrow \mathbb{R}$. Potom pre nutné podmienky prvého rádu (1.3), (1.4) dostávame

$$\nabla_x L(\hat{\mathbf{x}}, \hat{\mathbf{v}}) = 0,$$

$$\nabla_v L(\hat{\mathbf{x}}, \hat{\mathbf{v}}) = 0,$$

čiže bod $(\hat{\mathbf{x}}, \hat{\mathbf{v}})$ je kritickým bodom Lagrangeovej funkcie na $\mathbb{R}^n \times \mathbb{R}^p$.

Ukazuje sa, že tvrdenia (1.3) - (1.5) vety 1.1 môžeme využiť pri formulácii postačujúcich podmienok pre $\hat{\mathbf{x}}$ takto: ak $\hat{\mathbf{x}}$ a $\hat{\mathbf{v}}$ spĺňajú sústavu (1.3), (1.4) a v podmienke (1.5) platí pre všetky $\boldsymbol{\omega} \neq 0$ ostrá nerovnosť, potom $\hat{\mathbf{x}}$ je ostrým (lokálnym) optimálnym riešením úlohy (\mathcal{PR}) . Navyše nie je nutné predpokladať regularitu bodu $\hat{\mathbf{x}}$.

Dôležitou vlastnosťou bodu $(\hat{\mathbf{x}}, \hat{\mathbf{v}})$ vo vzťahu k Lagrangeovej funkcií (1.6) je jeho sedlovosť, ako vyplýva z nasledujúcej vety (predpoklad $f \in C^1, h \in C^1$ nie je potrebný).

Veta 1.2. *Nech bod $(\hat{\mathbf{x}}, \hat{\mathbf{v}}) \in \mathbb{R}^n \times \mathbb{R}^p$ splňa*

$$L(\hat{\mathbf{x}}, \mathbf{v}) \leq L(\hat{\mathbf{x}}, \hat{\mathbf{v}}) \leq L(\mathbf{x}, \hat{\mathbf{v}}) \quad \forall \mathbf{x} \in \mathbb{R}^n, \forall \mathbf{v} \in \mathbb{R}^p, \quad (1.7)$$

čiže je sedlovým bodom Lagrangeovej funkcie (1.6). Potom $\hat{\mathbf{x}}$ je optimálnym riešením úlohy (\mathcal{PR}) .

DÔKAZ: Dá sa dokázať analogicky ako Tvrdenie 1 v [41]. □

Uvedené výsledky použijeme na odvodenie nutných a postačujúcich podmienok pre úlohu s ohraničením v tvaru nerovností.

1.2 Úloha s ohraničeniami v tvaru nerovníc

Na tomto mieste sa budeme zaoberať úlohou

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g_i(\mathbf{x}) \geq 0, \quad i = 1, \dots, m. \end{aligned} \quad (\mathcal{PNR})$$

Analogicky ako v časti 1.1 predpokladajme $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ($i = 1, \dots, m$), $f \in C^1, g_i \in C^1$ pre všetky i , a takisto zavedieme označenie

$$g(\mathbf{x}) = (g_1(\mathbf{x}), \dots, g_m(\mathbf{x}))^\top,$$

čiže $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$. Množina prípustných riešení úlohy (\mathcal{PNR}) nadobúda tvar

$$\mathbb{M} = \{\mathbf{x} \mid g(\mathbf{x}) \geq 0\}.$$

Pre potreby ďalšej analýzy zavedeme pre $\mathbf{x} \in \mathbb{M}$ označenie

$$I_A(\mathbf{x}) = \{i \mid g_i(\mathbf{x}) = 0\} \quad (1.8)$$

pre množinu indexov aktívnych ohraničení v bode \mathbf{x} , a takisto definujme *regulárny* bod.

Definícia 1.2. Bod $\hat{\mathbf{x}} \in \mathbb{M}$ nazývame regulárnym, ak sú gradienty aktívnych ohraničení $\nabla g_i(\hat{\mathbf{x}}), \forall i \in I_A(\hat{\mathbf{x}})$ lineárne nezávislé.

Označme $q = |I_A(\hat{\mathbf{x}})|$ počet aktívnych ohraničení v $\hat{\mathbf{x}}$ a podobne ako v časti 1.1 predpokladajme $q \leq n$. Pre odvodenie nasledujúcich tvrdení najskôr pretransformujeme úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$ zavedením doplnkových premenných $\xi_i, i = 1, \dots, m$ na úlohu $(\mathcal{P}\mathcal{R})$ a použijeme vetu 1.1 na túto transformovanú úlohu. Výsledkom budú tzv. Karush-Kuhn-Tuckerove (KKT) podmienky (pre detaile tohto postupu viď [3], str. 312 - 313).

Definujme transformovaný problém

$$\begin{aligned} & \text{minimalizovať} \quad f(\mathbf{x}) \\ & \text{za podmienok} \quad \xi_i^2 - g_i(\mathbf{x}) = 0, \quad i = 1, \dots, m. \end{aligned} \quad (1.9)$$

Nech $\hat{\mathbf{x}}$ je lokálnym riešením úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$ a takisto nech je regulárnym bodom (podľa def. 1.2), potom bod $(\hat{\mathbf{x}}, \hat{\boldsymbol{\xi}}) = (\hat{\mathbf{x}}, \sqrt{g_1(\hat{\mathbf{x}})}, \dots, \sqrt{g_m(\hat{\mathbf{x}})})$ je lokálnym riešením úlohy (1.9) a takisto je regulárnym bodom tejto úlohy (def. 1.1), čo ľahko ukážeme. Ak označíme $r_i(\mathbf{x}, \boldsymbol{\xi}) = \xi_i^2 - g_i(\mathbf{x}), i = 1, \dots, m$ a použijeme pomocné označenie $r(\mathbf{x}, \boldsymbol{\xi}) = (r_1(\mathbf{x}, \boldsymbol{\xi}), \dots, r_m(\mathbf{x}, \boldsymbol{\xi}))^\top$, potom matica

$$\nabla r(\hat{\mathbf{x}}, \hat{\boldsymbol{\xi}}) = \begin{bmatrix} -\nabla g_1(\hat{\mathbf{x}})^\top & 2\hat{\boldsymbol{\xi}}_1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ -\nabla g_m(\hat{\mathbf{x}})^\top & 0 & \cdots & 2\hat{\boldsymbol{\xi}}_m \end{bmatrix}$$

má hodnosť m . Aplikujme teda nutné podmienky prvého rádu vety 1.1 na úlohu (1.9), podľa ktorých existuje (jednoznačne určený) vektor Lagrangeových multiplikátorov $\hat{\mathbf{u}} = (\hat{\mathbf{u}}_1, \dots, \hat{\mathbf{u}}_m)^\top$ taký, že platí

$$\begin{aligned} \nabla f(\hat{\mathbf{x}}) + \sum_{i=1}^m \hat{\mathbf{u}}_i \nabla r_i(\hat{\mathbf{x}}) &= 0, \\ \hat{\boldsymbol{\xi}}_i &= \sqrt{g_i(\hat{\mathbf{x}})}, \quad i = 1, \dots, m, \end{aligned}$$

čo je ekvivalentné s

$$\nabla f(\hat{\mathbf{x}}) - \sum_{i=1}^m \hat{\mathbf{u}}_i \nabla g_i(\hat{\mathbf{x}}) = 0, \quad (1.10)$$

$$2\hat{\mathbf{u}}_i \sqrt{g_i(\hat{\mathbf{x}})} = 0, \quad i = 1, \dots, m. \quad (1.11)$$

Z (1.11) máme $\hat{\mathbf{u}}_i = 0$ pre $i \notin I_A(\mathbf{x})$, čo môžeme zapísť ako

$$\hat{\mathbf{u}}_i g_i(\hat{\mathbf{x}}) = 0, \quad i = 1, \dots, m. \quad (1.12)$$

Ak naviac predpokladáme $f \in C^2, g \in C^2$, potom aplikovaním podmienky druhého rádu (1.5) vety 1.1 máme

$$[\boldsymbol{\omega}^T \quad \boldsymbol{\lambda}^T] \begin{bmatrix} \nabla_{xx}^2 L(\hat{\mathbf{x}}, \hat{\mathbf{u}}) & 0 \\ 0 & 2 \text{diag}(\hat{\mathbf{u}}) \end{bmatrix} \begin{bmatrix} \boldsymbol{\omega} \\ \boldsymbol{\lambda} \end{bmatrix} \geq 0 \quad (1.13)$$

pre všetky $(\boldsymbol{\omega}, \boldsymbol{\lambda}) \in \mathbb{R}^{n+m}$ spĺňajúce

$$2\hat{\xi}_i \boldsymbol{\lambda}_i - \nabla g_i(\hat{\mathbf{x}})^T \boldsymbol{\omega} = 0, \quad i = 1, \dots, m. \quad (1.14)$$

pričom sme označili

$$L(\mathbf{x}, \mathbf{u}) = f(\mathbf{x}) - \sum_{i=1}^m \mathbf{u}_i g_i(\mathbf{x}), \quad L : \mathbb{R}^n \times \mathbb{R}_+^m \longrightarrow \mathbb{R}. \quad (1.15)$$

Ak zvolíme $\boldsymbol{\lambda}_i = 0$ pre $i \in I_A(\hat{\mathbf{x}})$ a využitím (1.12) a (1.13) dostaneme

$$\boldsymbol{\omega}^T \nabla_{xx} L(\hat{\mathbf{x}}, \hat{\mathbf{u}}) \boldsymbol{\omega} \geq 0$$

pre $\boldsymbol{\omega}$ spĺňajúce $\nabla g_i(\hat{\mathbf{x}})^T \boldsymbol{\omega} = 0$ pre $i \in I_A(\hat{\mathbf{x}})$. Ďalej môžeme pre každé $i \in I_A(\hat{\mathbf{x}})$ vo vzťahu (1.13) zvoliť $\boldsymbol{\omega} = 0, \boldsymbol{\lambda}_i \neq 0$ a $\boldsymbol{\lambda}_j = 0$ pre $i \neq j$ a dostaneme

$$\hat{\mathbf{u}}_i \geq 0, \quad i \in I_A(\hat{\mathbf{x}}). \quad (1.16)$$

Týmto názorným postupom sme dostali sústavu podmienok (1.10), (1.12) a (1.16), ktoré spolu s podmienkou prípustnosti $g(\hat{\mathbf{x}}) \geq 0$ tvoria nutné podmienky prvého rádu pre úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$ (spomínané Karush-Kuhn-Tuckerove podmienky). Museli sme však dodatočne predpokladať, že $f \in C^2, g \in C^2$. Karush-Kuhn-Tuckerove podmienky však platia aj bez tohto predpokladu, čo nám umožnuje sformulovať nasledujúcu vetu.

Veta 1.3. Nech $\hat{\mathbf{x}}$ je lokálnym riešením úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$ a takisto regulárnym bodom. Potom existuje (jednoznačne určený) vektor Lagrangeových multiplikátorov $\hat{\mathbf{u}} = (\hat{\mathbf{u}}_1, \dots, \hat{\mathbf{u}}_m)^T$ taký, že platí

$$\nabla f(\hat{\mathbf{x}}) - \sum_{i=1}^m \hat{\mathbf{u}}_i \nabla g_i(\hat{\mathbf{x}}) = 0, \quad (1.17)$$

$$g(\hat{\mathbf{x}}) \geq 0, \quad (1.18)$$

$$\hat{\mathbf{u}}^T g(\hat{\mathbf{x}}) = 0, \quad (1.19)$$

$$\hat{\mathbf{u}} \geq 0. \quad (1.20)$$

Ak naviac $f \in C^2$, $g \in C^2$, potom platí

$$\boldsymbol{\omega}^T \left[\nabla^2 f(\hat{\mathbf{x}}) - \sum_{i=1}^m \hat{\mathbf{u}}_i \nabla^2 g_i(\hat{\mathbf{x}}) \right] \boldsymbol{\omega} \geq 0 \quad (1.21)$$

pre všetky $\boldsymbol{\omega}$ také, že $\nabla g_i(\hat{\mathbf{x}})^T \boldsymbol{\omega} = 0$ pre $i \in I_A(\hat{\mathbf{x}})$.

DÔKAZ: Priamy dôkaz bez transformácie na úlohu (\mathcal{PR}) a bez nutnosti predpokladu $f \in C^2, g \in C^2$ pre odvodenie vzťahov (1.17) - (1.20) je možné nájsť v [24], str. 342-343. \square

Kedže platí $\hat{\mathbf{u}} \geq 0$ a $g(\hat{\mathbf{x}}) \geq 0$, potom (1.19) je ekvivalentné s

$$\hat{\mathbf{u}}_i g_i(\hat{\mathbf{x}}) = 0, \quad i = 1, \dots, m. \quad (1.22)$$

Tento výraz nazývame *podmienkou komplementarity*, keďže z neho vyplýva, že aspoň jeden z výrazov $\hat{\mathbf{u}}_i, g_i(\hat{\mathbf{x}})$ je nulový. Ak je nulový práve jeden, čiže ak

$$\hat{\mathbf{u}}_i > 0 \quad \text{pre } i \in I_A(\hat{\mathbf{x}}), \quad (1.23)$$

hovoríme, že platí *podmienka ostrej komplementarity*.

Podobne ako v časti 1.1 môžeme formulovať postačujúce podmienky takto: Nech bod $(\hat{\mathbf{x}}, \hat{\mathbf{u}})$ spĺňa (1.17) - (1.20), v podmienke (1.21) platí pre všetky $\boldsymbol{\omega} \neq 0$ ostrá nerovnosť a naviac je splnená podmienka ostrej komplementarity. Potom $\hat{\mathbf{x}}$ je ostrým (lokálnym) optimálnym riešením úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$.

Rovnako platí, že sedlovosť bodu $(\hat{\mathbf{x}}, \hat{\mathbf{u}})$ implikuje optimalitu $\hat{\mathbf{x}}$.

Veta 1.4. Nech bod $(\hat{\mathbf{x}}, \hat{\mathbf{u}}) \in \mathbb{R}^n \times \mathbb{R}_+^m$ splňa

$$L(\hat{\mathbf{x}}, \mathbf{u}) \leq L(\hat{\mathbf{x}}, \hat{\mathbf{u}}) \leq L(\mathbf{x}, \hat{\mathbf{u}}) \quad \forall \mathbf{x} \in \mathbb{R}^n, \forall \mathbf{u} \in \mathbb{R}_+^m, \quad (1.24)$$

čiže je sedlovým bodom Lagrangeovej funkcie (1.15). Potom $\hat{\mathbf{x}}$ je riešením úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$.

DÔKAZ: Veta je prvým tvrdením v [41]. □

Je nutné poznamenať, že pre všeobecné funkcie f, g a h nevieme dokázať viac než len *lokálnu* platnosť uvedených viet (okrem viet o sedlových bodoch). K dokáza- niu globálnej platnosti je potrebné, aby bola v istom zmysle „pekná“ nielen účelová funkcia, ale aj množina prípustných riešení \mathbb{M} . Tieto neurčité požiadavky je možné splniť napríklad predpokladaním konvexnosti účelovej funkcie a množiny \mathbb{M} . Dostaneme tak formuláciu úlohy *konvexného programovania*.

1.3 Úloha konvexného programovania a teória duality

Úlohou konvexného programovania je minimalizácia konvexnej funkcie na konvexnej množine. Uvedme najprv niektoré poznatky z konvexnej analýzy. Výborným zdrojom z tejto oblasti je publikácia [38].

Množinu \mathcal{C} nazývame *konvexnou*, ak \mathcal{C} obsahuje celú priamku spájajúcu ľubovoľné dva body, ktoré v nej ležia, alebo inak

$$\alpha \mathbf{x} + (1 - \alpha) \mathbf{y} \in \mathcal{C}, \quad \forall \mathbf{x}, \mathbf{y} \in \mathcal{C}, \mathbf{x} \neq \mathbf{y}, \alpha \in (0, 1). \quad (1.25)$$

Množina, ktorá vznikne prienikom ľubovoľného počtu konvexných množín, je konvexná.

Vektorový súčet

$$\alpha_1 \mathbf{x}_1 + \cdots + \alpha_k \mathbf{x}_k$$

nazývame *konvexnou kombináciou* vektorov $\mathbf{x}_1, \dots, \mathbf{x}_k$, ak platí $\alpha_1 + \cdots + \alpha_k = 1$ a $\alpha_i \geq 0$ ($i = 1, \dots, k$). Potom množina \mathcal{C} je konvexná práve vtedy, ak obsahuje všetky konvexné kombinácie svojich prvkov.

Funkciu $f : \mathbb{S} \rightarrow \mathbb{R}$, $\mathbb{S} \subseteq \mathbb{R}^n$ nazveme *konvexnou*, ak jej *epigraf*

$$\text{epi } f = \{(\mathbf{x}, \mu) \mid \mathbf{x} \in \mathbb{S}, \mu \in \mathbb{R}, f(\mathbf{x}) \leq \mu\}$$

je konvexná množina ako podmnožina \mathbb{R}^{n+1} . Takisto platí

$$f(\alpha \mathbf{x} + (1 - \alpha) \mathbf{y}) \leq \alpha f(\mathbf{x}) + (1 - \alpha) f(\mathbf{y}), \quad \forall \mathbf{x}, \mathbf{y} \in \mathbb{S}, \alpha \in (0, 1), \quad (1.26)$$

čiže úsečka spájajúca ľubovoľné dva body funkcie f leží nad jej grafom. Pre $f \in C^1$ platí

$$f(\mathbf{x}) \geq f(\mathbf{y}) + \nabla f(\mathbf{y})^\top (\mathbf{x} - \mathbf{y}), \quad \forall \mathbf{x}, \mathbf{y} \in \mathbb{S}. \quad (1.27)$$

Graf funkcie f teda leží nad jej ľubovoľnou dotykovou nadrovinou.

Pre *rýdzokonvexnú* funkciu platia vzťahy (1.26) a (1.27) s ostrými nerovnosťami. Dodajme ešte, že funkciu f nazývame *konkávnou*, ak $-f$ je konvexná.

Ak f je konvexná, potom jej Hessova matica je kladne semidefinitná, Hessián rýdzokonvexnej funkcie je kladne definitný.

Do nasledujúcej vety zarádime dva dôležité poznatky o konvexných funkciách.

Veta 1.5. *Platí:*

- (a) Nezáporná kombinácia konvexných funkcií je konvexnou funkciou.
- (b) Nech $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je konvexná funkcia a \mathcal{C} je konvexná množina. Potom lokálne minimum funkcie f na množine \mathcal{C} je tiež globálnym minimum. Ak je f rýdzokonvexná, potom existuje najviac jedno globálne minimum f na \mathcal{C} .

DÔKAZ: Tvrdenie (a) možno nájsť v [20], str. 78, časť (b) nájdeme napríklad v [2], str. 87. \square

1.3.1 Postačujúce podmienky optimality

Teraz už môžeme sformulovať úlohu konvexného programovania

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g_i(\mathbf{x}) \geq 0, \quad i = 1, \dots, m, \end{aligned} \quad (\mathcal{PNR}_c)$$

kde predpokladáme $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ($i = 1, \dots, m$), f je konvexná a g_i sú konkávne funkcie. Na základe vety 1.5 môžeme očakávať, že obdobné tvrdenia o

optimálnom riešení z časti 1.2 budú pre úlohu $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ platiť v globálnom meradle. Skutočne, Karush-Kuhn-Tuckerove podmienky budú postačujúcou podmienkou pre optimálne riešenie, ako vyplýva z nasledujúceho tvrdenia.

Veta 1.6. Majme úlohu konvexného programovania $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ a predpokladajme, že $f \in C^1, g \in C^1$. Nech bod $(\hat{\mathbf{x}}, \hat{\mathbf{u}}) \in \mathbb{R}^n \times \mathbb{R}_+^m$ splňa

$$\nabla f(\hat{\mathbf{x}}) - \sum_{i=1}^m \hat{\mathbf{u}}_i \nabla g_i(\hat{\mathbf{x}}) = 0, \quad (1.28)$$

$$g(\hat{\mathbf{x}}) \geq 0, \quad (1.29)$$

$$\hat{\mathbf{u}}^T g(\hat{\mathbf{x}}) = 0, \quad (1.30)$$

$$\hat{\mathbf{u}} \geq 0. \quad (1.31)$$

Potom $\hat{\mathbf{x}}$ je (globálnym) optimálnym riešením.

DÔKAZ: Nájdeme v [21]. □

Vidíme, že regularita bodu $\hat{\mathbf{x}}$ nie je potrebná a takisto je automaticky splnená podmienka druhého rádu (1.21) analogickej vety 1.3, keďže Lagrangeova funkcia

$$L(\mathbf{x}, \mathbf{u}) = f(\mathbf{x}) - \sum_{i=1}^m \mathbf{u}_i g_i(\mathbf{x}), \quad L : \mathbb{R}^n \times \mathbb{R}_+^m \longrightarrow \mathbb{R}, \quad (1.32)$$

je konvexná (podľa vety 1.5, tvrdenie **(a)**). Niektoré ďalšie tvrdenia týkajúce sa úlohy konvexného programovania uvedieme v súvislosti s jej *duálnou* úlohou.

1.3.2 Duálna úloha a teória duality

V tejto časti spomenieme niekoľko výsledkov a tvrdení *teórie duality*, ktorá skúma vlastnosti tzv. *duálnej úlohy*. Túto úlohu možno chápať ako „doplňkovú“ úlohu k úlohe $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ v premennej \mathbf{u} , pričom vzájomný vzťah týchto úloh je daný bodom $(\hat{\mathbf{x}}, \hat{\mathbf{u}})$. Takýto pohľad na problematiku umožnuje nazerať na vektor multiplikátorov \mathbf{u} ako na rovnocennú veličinu s primárnym vektorom \mathbf{x} (pre podrobnosti pozri [2], kap. 5).

Budeme sa venovať konvexnej úlohe

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g_i(\mathbf{x}) \geq 0, \quad i = 1, \dots, m, \end{aligned} \quad (\mathcal{P}\mathcal{N}\mathcal{R}_C)$$

no niektoré vlastnosti duality je možné rozšíriť aj na všeobecnú úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$, prípadne $(\mathcal{P}\mathcal{R})$. Pre zjednoušenie niektorých zápisov označme

$$\mathbb{M} = \{\mathbf{x} \mid g_i(\mathbf{x}) \geq 0, i = 1, \dots, m\}$$

množinu prípustných riešení úlohy $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$. Predpokladajme naviac, že $f(\hat{\mathbf{x}}) > -\infty$. Úlohu $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ nazveme v kontexte duality *primárnu* a označíme

$$\hat{f} = \min_{\mathbf{x} \in \mathbb{M}} f(\mathbf{x})$$

jej optimálnu hodnotu. Vďaka nej môžeme uviesť alternatívnu definíciu optimálneho vektora Lagrangeových multiplikátorov.

Definícia 1.3 (Lagrangeov multiplikátor). *Vektor $\hat{\mathbf{u}}$ nazveme optimálnym vektorom Lagrangeových multiplikátorov pre primárnu úlohu $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$, ak $\hat{\mathbf{u}} \geq 0$ a*

$$\hat{f} = \min_{\mathbf{x} \in \mathbb{R}^n} L(\mathbf{x}, \hat{\mathbf{u}}).$$

Definujme *duálnu funkciu d* predpisom

$$d(\mathbf{u}) = \min_{\mathbf{x} \in \mathbb{R}^n} L(\mathbf{x}, \mathbf{u}) \quad (1.33)$$

a priraďme k nej *duálnu úlohu*

$$\begin{array}{ll} \text{maximalizovať} & d(\mathbf{u}) \\ \text{za podmienok} & \mathbf{u} \geq 0. \end{array} \quad (\mathcal{D}\mathcal{N}\mathcal{R}_C)$$

Z definície funkcie d vyplýva, že je konkávna, a označme

$$\hat{d} = \max_{\mathbf{u} \geq 0} d(\mathbf{u})$$

jej optimálnu hodnotu. Vzťah úloh $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ a $(\mathcal{D}\mathcal{N}\mathcal{R}_C)$ popíšeme pomocou *slabej vety o dualite*.

Veta 1.7 (Slabá veta o dualite). *Platí*

$$\hat{d} \leq \hat{f}.$$

Ak $\hat{d} = \hat{f}$, hovoríme, že platí *silná dualita*, a ak $\hat{d} < \hat{f}$, hovoríme o výskytte *duálnej medzery*. Existencia optimálneho vektora Lagrangeových multiplikátorov z definície 1.3 implikuje platnosť silnej duality, a v tomto prípade takisto platí, že $\hat{\mathbf{u}}$ je

optimálnym vektorom Lagrangeových multiplikátorov pre $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ práve vtedy, ak je optimálnym riešením úlohy $(\mathcal{D}\mathcal{N}\mathcal{R}_C)$.

Ak existuje duálna medzera, potom je množina optimálnych vektorov Lagrangeových multiplikátorov prázdna. Za určitých doplňujúcich predpokladov (napr. existencia vnútorného bodu, t.j. $\exists \bar{\mathbf{x}} : g(\bar{\mathbf{x}}) > 0 \forall i$) platí silná dualita pre úlohy $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ a $(\mathcal{D}\mathcal{N}\mathcal{R}_C)$. Potom namiesto riešenia jednej z nich môžeme exvivalentne riešiť druhú, napríklad s cieľom využiť jej výhodnejšiu štruktúru (napríkald lineárne a kvadratické programovanie). Moderným prístupom je riešiť oba problémy „súčasne“, na základe čoho ich potom nazývame primárno-duálnymi metódami.

Na záver ešte uvedieme dve vety.

Veta 1.8. *Vektor $\hat{\mathbf{x}} \in \mathbb{R}^n$ je optimálnym riešením úlohy $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ a $\hat{\mathbf{u}} \in \mathbb{R}_+^m$ je optimálnym riešením úlohy $(\mathcal{D}\mathcal{N}\mathcal{R}_C)$ vtedy a len vtedy, ak $(\hat{\mathbf{x}}, \hat{\mathbf{u}})$ je sedlovým bodom Lagrangeovej funkcie*

$$L(\hat{\mathbf{x}}, \mathbf{u}) \leq L(\hat{\mathbf{x}}, \hat{\mathbf{u}}) \leq L(\mathbf{x}, \hat{\mathbf{u}}), \quad \forall \mathbf{x} \in \mathbb{R}^n, \forall \mathbf{u} \in \mathbb{R}_+^m.$$

Záverečná veta predstavuje postačujúce podmienky pre všeobecnú úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$ cez globálne minimum Lagrangeovej funkcie $L(\cdot, \hat{\mathbf{u}})$.

Veta 1.9. *Nech $\hat{\mathbf{u}}$ je optimálny vektor Lagrangeových multiplikátorov. Potom $\hat{\mathbf{x}}$ je globálnym riešením primárnej úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$ vtedy a len vtedy, ak $\hat{\mathbf{x}} \in \mathbb{M}$ a*

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x} \in \mathbb{R}^n} L(\mathbf{x}, \hat{\mathbf{u}}), \quad \hat{\mathbf{u}}^T g(\hat{\mathbf{x}}) = 0.$$

Sedlový bod Lagrangeovej funkcie je kľúčovým objektom pri hľadaní optimálneho riešenia úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$, prípadne $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$. Algoritmické využitie klasickej Lagrangeovej funkcie však nie je postačujúce. Jedným z možných spôsobov je použitie tzv. rozšírených Lagrangeových funkcií, ktorých hlavné myšlienky si predstavíme v nasledujúcej časti.

Kapitola 2

Metódy rozšírených Lagrangeových funkcií

V predchádzajúcej kapitole sme vyjadrili vo vete 1.3 pomocou klasickej Lagrangeovej funkcie nutné a v prípade konvexnej úlohy aj postačujúce podmienky pre optimálne riešenie úlohy (\mathcal{PNR}), ktoré sú realizované sústavou rovníc a nerovníc (1.17) - (1.20). Každá dvojica vektorov $(\hat{\mathbf{x}}, \hat{\mathbf{u}})$, ktorá rieši tento systém, predstavuje kandidátov na (lokálne) optimálne riešenie. Snaha o algoritmické hľadanie takejto dvojice pomocou sedlového bodu klasickej Lagrangeovej funkcie má niekoľko nedostatkov. V tejto časti sa preto budeme zaoberať skupinou metód, ktorých hlavným nástrojom je *rozšírená* Lagrangeova funkcia.

Hlavnou ideou metód rozšírených Lagrangeových funkcií je approximovať pôvodnú úlohu (\mathcal{PNR}) sekvenciou subproblémov, ktorých riešenie je výrazne jednoduchšie. Riešením uvedených subproblémov budeme generovať postupnosť bodov $\{\mathbf{x}^k\}, \{\mathbf{u}^k\}$, ktoré budú stále lepšími approximáciami optimálneho riešenia. Hoci táto schéma vytvára nekonečnú postupnosť approximácií, z praktického hľadiska ju však stačí ukončiť, ak sme dostatočne spokojní s kvalitou approximácie.

Koncepcia metód rozšírených Lagrangeových funkcií je veľmi podobná klasickým penalizačným metódam z 50. a 60. rokov minulého storočia. V týchto metódach zanedbáme niektoré alebo všetky ohraničenia a k hodnote účelovej funkcie pripočítame penalizačný člen, ktorý priradí vysokú hodnotu všetkým neprípustným vektorom \mathbf{x} . K penalizačnému členu je priradený parameter r^k , ktorý kontroluje veľkosť penalizácie. Cieľom je potom generovať postupnosť $\{r^k\} \rightarrow \infty$, ktorá zaručí, že $\{\mathbf{x}^k\} \rightarrow \hat{\mathbf{x}}$,

kde \mathbf{x}^k určíme ako minimum príslušnej penalizovanej funkcie. Avšak práve požiadavka $\{r^k\} \rightarrow \infty$, ktorá spôsobuje výrazné zhoršenie podmienosti problému a tiež pomerne pomalá konvergencia sú hlavnými nedostatkami penalizačných metód. Tieto fakty boli jedným z dôvodov, ktoré podnietili vznik prvých metód rozšírených Lagrangeových funkcií, ktoré tieto negatíva do značnej miery eliminujú.

Predtým, ako sa dostaneme k bližšej analýze niektorých metód z triedy rozšírených Lagrangeových funkcií, uvedieme pomerne všeobecnú vetu o sedlovom bode.

Veta 2.1 (Roode). *Majme všeobecnú úlohu matematického programovania*

$$\begin{aligned} & \text{minimalizovať} \quad f(\mathbf{x}) \\ & \text{za podmienok} \quad \mathbf{x} \in \mathbb{M} \end{aligned} \tag{2.1}$$

kde $\mathbb{M} \subset \mathbb{X} \subseteq \mathbb{R}^n$ a $f : \mathbb{X} \rightarrow \mathbb{R}$. Nech $\mathbb{Y} \subseteq \mathbb{R}^m$ a $\Gamma : \mathbb{X} \times \mathbb{Y} \rightarrow \mathbb{R}$ má nasledovné vlastnosti:

$$(\mathbf{A1}) \quad \forall \boldsymbol{\mu} \in \mathbb{Y}, \quad \forall \mathbf{x} \in \mathbb{M} : \quad \Gamma(\mathbf{x}, \boldsymbol{\mu}) \leq 0$$

$$(\mathbf{A2}) \quad \exists \bar{\boldsymbol{\mu}} \in \mathbb{Y}, \quad \forall \mathbf{x} \in \mathbb{M} : \quad \Gamma(\mathbf{x}, \bar{\boldsymbol{\mu}}) = 0$$

$$(\mathbf{A3}) \quad \forall \mathbf{x} \notin \mathbb{M} : \quad \sup_{\boldsymbol{\mu} \in \mathbb{Y}} \Gamma(\mathbf{x}, \boldsymbol{\mu}) = \infty$$

Nech $(\hat{\mathbf{x}}, \hat{\boldsymbol{\mu}}) \in \mathbb{X} \times \mathbb{Y}$ je sedlovým bodom rozšírenej Lagrangeovej funkcie

$$\mathcal{L}(\mathbf{x}, \boldsymbol{\mu}) = f(\mathbf{x}) + \Gamma(\mathbf{x}, \boldsymbol{\mu}), \tag{2.2}$$

$\mathcal{L} : \mathbb{X} \times \mathbb{Y} \rightarrow \mathbb{R}$ v zmysle

$$\mathcal{L}(\hat{\mathbf{x}}, \hat{\boldsymbol{\mu}}) \leq \mathcal{L}(\hat{\mathbf{x}}, \boldsymbol{\mu}) \leq \mathcal{L}(\mathbf{x}, \hat{\boldsymbol{\mu}}), \quad \forall \mathbf{x} \in \mathbb{X}, \quad \forall \boldsymbol{\mu} \in \mathbb{Y}. \tag{2.3}$$

Potom $\hat{\mathbf{x}}$ je (lokálnym) optimálnym riešením úlohy (2.1).

DÔKAZ: Je možné nájsť v [21]. □

Analógia s vetami o sedlovom bode z predošlých častí teda platí aj pre rozšírené Lagrangeove funkcie definované vzťahom (2.2), pričom ich penalizačná funkcia Γ musí spĺňať podmienky **(A1)-(A3)**, ktoré budeme nazývať *Roodeho axiómy*.

Prvú metódu z triedy rozšírených Lagrangeových funkcií rozpracovali Hestenes [22] a nezávisle Powell [35] pre úlohu (\mathcal{PR}) . Práve tejto metóde, v literatúre niekedy označovanej ako klasická metóda multiplikátorov [1], venujeme nasledujúcu časť.

2.1 Metóda Hestenesa a Powella pre úlohu s ohraňčeniami v tvare rovníc

V tejto časti budeme uvažovať úlohu v tvare

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && h(\mathbf{x}) = 0 \end{aligned} \tag{\mathcal{PR}}$$

kde $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$, $f, h \in C^2$ sú dané funkcie, $h(\mathbf{x}) = (h_1(\mathbf{x}), \dots, h_p(\mathbf{x}))^\top$. Na tomto mieste zatiaľ nebudeme požadovať konvexnosť úlohy (\mathcal{PR}) a stručný prehľad metódy multiplikátorov urobíme vo všeobecnosti aj pre nekonvexné úlohy. Spomenieme však výhody a teoretické zjednodušenia, ktoré prináša konvexná úloha (v tomto prípade je potrebné, aby f bola konvexná a všetky funkcie h_j affinné).

Predpokladajme, že optimálne riešenie $\hat{\mathbf{x}}$ úlohy (\mathcal{PR}) spĺňa nasledujúci predpoklad.

Predpoklad 2.1. *Vektor $\hat{\mathbf{x}}$ je ostrým lokálnym minimom a regulárnym bodom úlohy (\mathcal{PR}) , pričom platí*

$$\boldsymbol{\omega}^\top \mathbf{L}(\hat{\mathbf{x}}, \hat{\mathbf{v}}) \boldsymbol{\omega} > 0$$

pre všetky $\boldsymbol{\omega} \neq 0$ splňajúce $\nabla h(\hat{\mathbf{x}}) \boldsymbol{\omega} = 0$

Tento predpoklad zabezpečuje ostrú lokálnu konvexnosť klasickej Lagrangeovej funkcie (1.6) na vybranom podpriestore. Definujme *rozšírenú Lagrangeovu funkciu* pre úlohu (\mathcal{PR}) ako

$$\begin{aligned} \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) &= f(\mathbf{x}) + \sum_{i=1}^p \left[z_i h_i(\mathbf{x}) + \frac{r}{2} h_i^2(\mathbf{x}) \right] \\ &= f(\mathbf{x}) + h(\mathbf{x})^\top \mathbf{z} + \frac{r}{2} h(\mathbf{x})^\top h(\mathbf{x}), \end{aligned} \tag{2.4}$$

kde r je kladný penalizačný parameter a \mathbf{z} označuje vektor zovšeobecnených Lagrangeových multiplikátorov. V súlade s vetou 2.1 máme $\Gamma(\mathbf{x}, \mathbf{z}) = h(\mathbf{x})^\top \mathbf{z} + \frac{r}{2} h(\mathbf{x})^\top h(\mathbf{x})$, $\mathbb{X} = \mathbb{R}^n$, $\mathbb{Y} = \mathbb{R}^p$ a $\mathbb{M} = \{\mathbf{x} \mid h(\mathbf{x}) = 0\}$, z čoho možno jednoducho overiť platnosť Roodeho axióm.

Funkcia (2.4) predstavuje určité *rozšírenie* klasickej Lagrangeovej funkcie, keďže

$$\mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) = \mathbf{L}(\mathbf{x}, \mathbf{z}) + \frac{r}{2} h(\mathbf{x})^\top h(\mathbf{x}).$$

Takisto je zrejmá podobnosť s pôvodnou penalizačnou funkciou, ktorá zodpovedá $\mathcal{L}_{\text{PH}}(\mathbf{x}, 0)$. Ďalej si všimnime, že platí

$$\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}, \boldsymbol{\mu}) = \nabla_x \mathbf{L}(\mathbf{x}, \bar{\boldsymbol{\mu}}), \quad \text{pre } \bar{\boldsymbol{\mu}} = \boldsymbol{\mu} + rh(\mathbf{x}),$$

a keďže pre optimálne riešenie $\hat{\mathbf{x}}$ platí $h(\hat{\mathbf{x}}) = 0$, máme $\nabla_x \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}) = \nabla_x \mathbf{L}(\hat{\mathbf{x}}, \hat{\mathbf{v}}) = 0$, z čoho nakoniec dostávame, že $\hat{\mathbf{z}} = \hat{\mathbf{v}}$. Vektory multiplikátorov \mathbf{v} a \mathbf{z} sa v optimálnom bode rovnajú.

Formálny popis jedného kroku klasického algoritmu Powell-Hestenesa je možné sformulovať takto:

Algoritmus (Powell-Hestenes). *Nech je daný Lagrangeov multiplikátor \mathbf{z}^k a penalizačný parameter r^k . Vektor \mathbf{x}^k získame minimalizáciou funkcie $\mathcal{L}_{\text{PH}}(\cdot, \mathbf{z}^k)$ na priesiore \mathbb{R}^n . Potom položíme*

$$\mathbf{z}^{k+1} = \mathbf{z}^k + r^k h(\mathbf{x}^k), \quad (2.5)$$

zvolíme nový penalizačný parameter $r^{k+1} \geq r^k$ a proces zopakujeme.

Počiatočný vektor \mathbf{z}^0 môže byť ľubovoľný a postupnosť r^k môže byť zvolená a priori, alebo na základe rýchlosť konvergencie podľa nejakého pravidla.

Je samozrejmé sa pýtať, či je algoritmus Powell-Hestenesa dobre definovaný, pričom otázkou môže byť najmä existencia minima funkcie $\mathcal{L}_{\text{PH}}(\cdot, \mathbf{z}^k)$, prípadne ako sa mení vzdialenosť týchto miním od bodu $\hat{\mathbf{x}}$ v závislosti od hodnoty multiplikátora \mathbf{z} a parametra r . Keďže máme

$$\nabla_x \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}) = \nabla f(\hat{\mathbf{x}}) + \nabla h(\hat{\mathbf{x}})^T [\hat{\mathbf{z}} + rh(\hat{\mathbf{z}})] = 0, \quad (2.6)$$

$$\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}) = \nabla_{xx}^2 \mathbf{L}(\hat{\mathbf{x}}, \hat{\mathbf{z}}) + r \nabla h(\hat{\mathbf{x}})^T \nabla h(\hat{\mathbf{x}}), \quad (2.7)$$

potom sa dá ukazať (napr. pomocou Lemmy 3.2.1 z [3]), že

$$\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}) > 0 \quad \forall r \geq \bar{r}, \quad (2.8)$$

kde \bar{r} je kritická hodnota penalizačného parametra (vopred neznáma). Teda na základe (2.6) a (2.8) vidíme, že $\hat{\mathbf{x}}$ je ostrým lokálnym minimom $\mathcal{L}_{\text{PH}}(\cdot, \hat{\mathbf{z}})$ pre všetky $r \geq \bar{r}$. Môžeme sa teda domnievať, že pre všetky \mathbf{z} dostatočne blízke k $\hat{\mathbf{z}}$ existuje minimum $\mathcal{L}_{\text{PH}}(\cdot, \mathbf{z})$ pre všetky $r \geq \bar{r}$. Ako uvidíme z nasledujúceho tvrdenia, minimum $\mathcal{L}_{\text{PH}}(\cdot, \mathbf{z})$ bude existovať aj pre \mathbf{z} vzdialené od $\hat{\mathbf{z}}$, ak je paramater r dostatočne veľký.

Veta 2.2. Nech je dané \bar{r} také, že

$$\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}) > 0$$

a nech platí predpoklad 2.1. Potom existujú kladné konštanty δ, ε, K , že platí

(a) Pre všetky $(\mathbf{z}, r) \in \mathbb{D} \subset \mathbb{R}^{p+1}$, kde \mathbb{D} je daná ako

$$\mathbb{D} = \{(\mathbf{z}, r) \mid \|\mathbf{z} - \hat{\mathbf{z}}\| < \delta r, r \geq \bar{r}\},$$

má úloha

$$\begin{aligned} &\text{minimalizovať } \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \\ &\text{za podmienok } \|\mathbf{x} - \hat{\mathbf{x}}\| < \varepsilon \end{aligned}$$

jediné riešenie $\mathbf{x}(\mathbf{z})$. Funkcia $\mathbf{x}(\mathbf{z})$ je spojito diferencovateľná vo vnútri množiny \mathbb{D} .

(b) Pre všetky $(\mathbf{z}, r) \in \mathbb{D}$ máme

$$\|\mathbf{x}(\mathbf{z}) - \hat{\mathbf{x}}\| \leq \frac{K}{r} \|\mathbf{z} - \hat{\mathbf{z}}\| \quad (2.9)$$

a

$$\|\bar{\mathbf{z}} - \hat{\mathbf{z}}\| \leq \frac{K}{r} \|\mathbf{z} - \hat{\mathbf{z}}\|, \quad (2.10)$$

kde

$$\bar{\mathbf{z}} = \mathbf{z} + rh(\mathbf{x}(\mathbf{z})),$$

(c) Pre všetky $(\mathbf{z}, r) \in \mathbb{D}$ je matica $\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z})$ kladne definitná a $\nabla h(\mathbf{x}(\mathbf{z}))$ má hodnosť p .

DÔKAZ: Dôkaz tvrdenia možno nájsť v [1], str. 108-111, alebo postupovať rovnako ako v [28]. \square

Skutočne vidíme, že aj keď zvolíme počiatočný vektor \mathbf{z}^0 príliš ďaleko od $\hat{\mathbf{z}}$, konvergenciu zaručíme voľbou dostatočne veľkého parametra $r \geq \bar{r}$. Pomocou tejto vety môžeme dokázať konvergenciu metódy a ukázať rýchlosť konvergencie v prípade, že iterácia multiplikátorov je daná vzťahom

$$\mathbf{z}^{k+1} = \mathbf{z}^k + r^k h(\mathbf{x}^k).$$

Presnejšie, ak označíme

$$\mathbf{B} = \left[\nabla h(\hat{\mathbf{x}}) (\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}))^{-1} \nabla h(\hat{\mathbf{x}})^T \right]^{-1} - r \mathbf{I} \quad (2.11)$$

pre všetky r také, že $(\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\hat{\mathbf{x}}, \hat{\mathbf{z}}))^{-1}$ existuje a ak

$$\bar{r} > \max_{i=1,\dots,p} \{-2e_i\},$$

kde e_i sú vlastné čísla matice \mathbf{B} , potom za určitých dodatočných predpokladoch o \mathbf{z}^0 a $r^0 \geq \bar{r}$ vieme ukázať, že $\{\mathbf{z}^k\} \rightarrow \hat{\mathbf{z}}$ a $\{\mathbf{x}(\mathbf{z}^k, r^k)\} \rightarrow \hat{\mathbf{x}}$. Naviac ak $\limsup_{k \rightarrow \infty} r^k = \hat{r} < \infty$ a $\mathbf{z}^k \neq \hat{\mathbf{z}}$ pre všetky k , potom

$$\limsup_{k \rightarrow \infty} \frac{\|\mathbf{z}^{k+1} - \hat{\mathbf{z}}\|}{\|\mathbf{z}^k - \hat{\mathbf{z}}\|} \leq \max_{i=1,\dots,p} \left| \frac{e_i}{e_i + \hat{r}} \right|, \quad (2.12)$$

a ak $\{r^k\} \rightarrow \infty$ a $\mathbf{z}^k \neq \hat{\mathbf{z}}$ pre všetky k , potom

$$\limsup_{k \rightarrow \infty} \frac{\|\mathbf{z}^{k+1} - \hat{\mathbf{z}}\|}{\|\mathbf{z}^k - \hat{\mathbf{z}}\|} = 0. \quad (2.13)$$

Teda z (2.12) vidíme, že algoritmus dosahuje lineárnu konvergenciu, ak je postupnosť r^k ohraničená a superlineárnu konvergenciu (podľa (2.13)), ak $r^k \rightarrow \infty$. Tieto odhady však vo všeobecnosti už nemožno zlepšíť.

Niekoľko poznámok k Powell-Hestenesovmu algoritmu:

- (a)** Opakovanie jednotlivých krokov Powell-Hestenesovho algoritmu je vo všeobecnosti nekonečný proces. Kvôli implementovateľnosti a výpočtovej náročnosti sa pri riešení jednotlivých minimalizačných subproblémov uspokojíme aj s približným riešením, teda takým, ktoré spĺňa

$$\|\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}_\alpha(\mathbf{z}), \mathbf{z})\| \leq \alpha.$$

Pre takto definovaný algoritmus vieme dokázať podobnú vetu ako je Veta 2.2, v ktorej uvažujeme množinu \mathbb{D} definovanú ako

$$\mathbb{D} = \left\{ (\mathbf{z}, r, \alpha) \mid \sqrt{\frac{\|\mathbf{z} - \hat{\mathbf{z}}\|^2}{r^2} + \|\alpha\|^2} < \delta, r \geq \bar{r} \right\}.$$

Potom sa pravé strany odhadov (2.9) a (2.10) zmenia na

$$\frac{K}{r} \sqrt{\|\mathbf{z} - \hat{\mathbf{z}}\|^2 + \|r\alpha\|^2}.$$

V platnosti zostanú aj odhady rýchlosť konvergencie (2.12) a (2.13).

- (b)** Pre prípad konvexného programovania dostávame samozrejme silnejšie výsledky. V tomto prípade stačí napríklad uvažovať ľubovoľné \bar{r} kladné ako kritickú hodnotu parametra r . Minimum funkcie $\mathcal{L}_{\text{PH}}(\cdot, \mathbf{z})$ existuje pre ľubovoľnú dvojicu $(\mathbf{z}, r) \in \mathbb{R}^p \times \mathbb{R}_{++}$. Takisto pre iteráciu multiplikátorov

$$\mathbf{z}^{k+1} = \mathbf{z}^k + r^k h(\mathbf{x}^k),$$

platí $\{\mathbf{z}^k\} \rightarrow \hat{\mathbf{z}}$ pre ľubovoľné hodnoty \mathbf{z}^0 a r^0 . Rýchlosť konvergencie zostáva v platnosti.

- (c)** Dôležitou otázkou z hľadiska praktických výpočtov zostáva, ako určiť postupnosť r^k . Počiatočná hodnota r^0 nesmie byť príliš veľká kvôli zhoršeniu podmiennosti úlohy v prvej minimalizačnej iterácii (Hestenes navrhuje použiť $\mathbf{z} = 0$ a teda prvá iterácia zodpovedá minimalizácii klasickej penalizačnej funkcie), a jeho hodnota nesmie rást príliš rýchlo. Často sa používa predpis $r^{k+1} = \gamma r^k$, napríklad pre $\gamma \in (1, 8]$. Inou možnosťou je zväčšiť r^k iba vtedy, ak $\|h(\mathbf{x}(\mathbf{z}^k))\|$ klesá k nule príliš „pomaly“. Ďalšou možnosťou je použiť vektor penalizačných parametrov, každý priradený jednému ohraničeniu a meniť len tie, ktorých ohraničenia nespĺňajú $\|h_i(\mathbf{x}(\mathbf{z}^{k+1}))\| < \beta \|h_i(\mathbf{x}(\mathbf{z}^k))\|$ pre $\beta \in (0, 1)$. Pre konvexné úlohy je možné ponechať $r^k = r^0$ pre všetky k . Idey zmeny penalizačného parametra sú uvedené napr. v [8].
- (d)** Otázka požadovanej presnosti minimalizácie vyjadrenej pomocou $\|\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}^k), \mathbf{z}^k)\|$ je takisto otvorená. Jednou z možností je požadovať, aby $\|\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}^k), \mathbf{z}^k)\| < \varepsilon^k$, kde $\{\varepsilon^k\} \rightarrow 0$, resp. $\varepsilon^k = \varepsilon^0 \ll 1 \forall k$. Bertsekas [1] navrhuje použiť

$$\varepsilon^k = \frac{\eta^k r^k}{2} \|h(\mathbf{x}(\mathbf{z}^k))\|^2,$$

pričom $\{\eta^k\} \rightarrow 0$ je vopred zvolená nezáporná postupnosť, a Polyak [33] používa

$$\varepsilon^k = \frac{\sigma}{r^k} \|\bar{\mathbf{z}} - \mathbf{z}^k\|,$$

kde $\bar{\mathbf{z}} = \mathbf{z}^k + r^k h(\mathbf{x}(\mathbf{z}^k))$ a $\sigma > 0$ je zvolená konštanta.

Doposiaľ sme sa príliš nevenovali motivácií pre iteráciu multiplikátorov v tvare

$$\mathbf{z}^{k+1} = \mathbf{z}^k + r^k h(\mathbf{x}^k).$$

Jednou z nich je fakt, že pre takto definovaný odhad multiplikátora \mathbf{z}^{k+1} platí $\nabla_x \mathcal{L}(\mathbf{x}^k, \mathbf{z}^{k+1}) = 0$. Ako uvidíme v ďalšej časti, z hľadiska duálnej funkcie pre problém (\mathcal{PR}) ide o iteráciu gradientnej metódy s krokom r^k .

2.1.1 Iterácie multiplikátorov

V tejto časti sa pokúsime zhrnúť základné poznatky o rôznych metódach odhadovania Lagrangeových multiplikátorov. V algoritme Powell-Hestenesa sme sa zatiaľ zmienili iba o jednej z nich (2.5), často nazývanej ako metóda prvého rádu. Ukážeme, že je možné odvodiť aj metódy, ktoré využívajú informáciu Hessovej matice rozšírenej Lagrangeovej funkcie, a preto sa s nimi môžeme v literatúre stretnúť pod názvom metódy druhého rádu. Ukážeme odvodenie týchto metód pomocou duálnej funkcie problému (\mathcal{PR}) , a ako sa neskôr ukáže, metóda bude zodpovedať jednej iterácii Newtonovej metódy aplikovanej na primárno-duálny systém rovníc. Dobrým zdrojom sú články Byrda [7], Tapiu [16], [43], a monografia Bertsekasa [1].

Nech \bar{r}, δ a ε sú ako vo vete (2.2), a pre dvojicu (\mathbf{z}, r) patriacu do množiny

$$\mathbb{D} = \{(\mathbf{z}, r) \mid \|\mathbf{z} - \hat{\mathbf{z}}\| < \delta r, r \geq \bar{r}\} \quad (2.14)$$

definujme duálnu funkciu predpisom

$$d_{\text{PH}}(\mathbf{z}) = \min_{\|\mathbf{x} - \hat{\mathbf{x}}\| < \varepsilon} \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) = f(\mathbf{x}(\mathbf{z})) + h(\mathbf{x}(\mathbf{z}))^\top \mathbf{z} + \frac{r}{2} h(\mathbf{x}(\mathbf{z}))^\top h(\mathbf{x}(\mathbf{z})). \quad (2.15)$$

Kedžže z vety (2.2) vieme, že $\mathbf{x}(\cdot)$ je diferencovateľná, potom to isté platí aj o $d_{\text{PH}}(\cdot)$. Spočítajme gradient a Hessovu maticu funkcie d_{PH} . Dostávame

$$\nabla_z d_{\text{PH}} = \nabla_z \mathbf{x}(\mathbf{z}) \nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) + h(\mathbf{x}(\mathbf{z})) \quad (2.16)$$

Kedžže

$$\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) = 0, \quad (2.17)$$

máme

$$\nabla_z d_{\text{PH}} = h(\mathbf{x}(\mathbf{z})). \quad (2.18)$$

Pre Hessovu maticu dostávame

$$\nabla_{zz}^2 d_{\text{PH}} = \nabla_z \mathbf{x}(\mathbf{z}) \nabla h(\mathbf{x}(\mathbf{z}))^\top. \quad (2.19)$$

S využitím, že pre všetky dvojice $(\mathbf{z}, r) \in \mathbb{D}$ máme (2.17), potom po derivovaní tohto vzťahu podľa \mathbf{z} máme

$$\nabla_z \mathbf{x}(\mathbf{z}) \nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) + \nabla_{xz}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) = 0$$

a s využitím

$$\nabla_{xz}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z})) = \nabla h(\mathbf{x}(\mathbf{z})).$$

dostávame

$$\nabla_z \mathbf{x}(\mathbf{z}) = -\nabla h(\mathbf{x}(\mathbf{z})) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) \right]^{-1}$$

a napokon

$$\nabla_{zz}^2 d_{\text{PH}} = -\nabla h(\mathbf{x}(\mathbf{z})) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) \right]^{-1} \nabla h(\mathbf{x}(\mathbf{z}))^T. \quad (2.20)$$

Kedžze z vety (2.2) máme, že $\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}(\mathbf{z}), \mathbf{z}) > 0$ a matica $\nabla h(\mathbf{x}(\mathbf{z}))$ má hodnosť p pre $(\mathbf{z}, r) \in \mathbb{D}$, dostávame z (2.20), že $\nabla_{zz}^2 d_{\text{PH}}(\mathbf{z}) < 0$ pre $(\mathbf{z}, r) \in \mathbb{D}$. Naviac, z (2.18) máme pre $r \geq \bar{r}$

$$\nabla d_{\text{PH}}(\hat{\mathbf{z}}) = h(\mathbf{x}(\hat{\mathbf{z}})) = h(\hat{\mathbf{x}}) = 0,$$

Teda, pre všetky $r \geq \bar{r}$, $\hat{\mathbf{z}}$ maximalizuje funkciu d_{PH} na množine $\{\mathbf{z} \mid \|\mathbf{z} - \hat{\mathbf{z}}\| < \delta r\}$. Potom môžeme iteráciu (2.5) zapísť ako

$$\mathbf{z}^{k+1} = \mathbf{z}^k + r^k \nabla d_{\text{PH}}(\mathbf{z}^k), \quad (2.21)$$

čiže iterácia (2.5) skutočne zodpovedá iterácií gradientnej metódy s krokom r^k .

Rovnako ako sme uvažovali iteráciu v tvare

$$\mathbf{z}^{k+1} = \mathbf{z}^k + r^k \nabla d_{\text{PH}}(\mathbf{z}^k),$$

môžeme uvažovať Newtonovu iteráciu (pozri prílohu A) na maximalizovanie funkcie d_{PH}

$$\mathbf{z}^{k+1} = \mathbf{z}^k - \left[\nabla_{zz}^2 d_{\text{PH}}(\mathbf{z}^k) \right]^{-1} \nabla d_{\text{PH}}(\mathbf{z}^k).$$

Po využití (2.18) a (2.20) dostávame vzťah

$$\mathbf{z}^{k+1} = \mathbf{z}^k + \left[\nabla h(\mathbf{x}^k) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}^k, \mathbf{z}^k) \right]^{-1} \nabla h(\mathbf{x}^k)^T \right]^{-1} h(\mathbf{x}^k). \quad (2.22)$$

Kvôli analýze konvergencie tohto odhadu uvažujme Newtonovu metódu na riešenie sústavy rovníc

$$\begin{aligned}\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) &= 0, \\ h(\mathbf{x}) &= 0,\end{aligned}$$

čiže (použili sme označenie $\Delta \mathbf{x} = \bar{\mathbf{x}} - \mathbf{x}$, $\Delta \mathbf{z} = \bar{\mathbf{z}} - \mathbf{z}$)

$$\begin{bmatrix} \nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) & \nabla h(\mathbf{x})^T \\ \nabla h(\mathbf{x}) & 0 \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{z} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \\ -h(\mathbf{x}) \end{bmatrix} \quad (2.23)$$

Za predpokladov invertovateľnosti matice $\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z})$ a plnej hodnosti matice $\nabla h(\mathbf{x})$ (hodnosť p) vieme tento systém explicitne vyriešiť. Ľahko sa možno prevedčiť, že $\bar{\mathbf{x}}, \bar{\mathbf{z}}$ sú dané vzťahmi

$$\bar{\mathbf{z}} = \mathbf{z} + \left[\nabla h(\mathbf{x}) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \right]^{-1} \nabla h(\mathbf{x})^T \right]^{-1} \times \quad (2.24)$$

$$\left[h(\mathbf{x}) - \nabla h(\mathbf{x}) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \right]^{-1} \nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \right]. \quad (2.25)$$

$$\bar{\mathbf{x}} = \mathbf{x} - \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \right]^{-1} \nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \quad (2.26)$$

Ak použijeme fakt, že $\nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) = 0$, zistíme, že (2.22) zodpovedá iterácii (2.24), čo nám pomôže pri analýze konvergencie. Podobne ako pre iteráciu (2.5) môžeme sformulovať nasledujúcu vetu.

Veta 2.3. *Nech platí predpoklad 2.1 a nech \bar{r} a δ sú totožné ako v (2.2). Potom k ľubovoľnej konštante γ existuje konštantă δ_2 , kde $0 < \delta_2 \leq \delta$ taká, že pre všetky dvojice (\mathbf{z}, r) z množiny \mathbb{D}_2 definovanej ako*

$$\mathbb{D}_2 = \{(\mathbf{z}, r) \mid \|\mathbf{z} - \hat{\mathbf{z}}\| < \delta_2 r, r \geq \bar{r}\},$$

dostávame nasledovné odhady:

(a) Platí

$$\|\bar{\mathbf{z}} - \hat{\mathbf{z}}\| \leq \frac{\gamma}{r} \|\mathbf{z} - \hat{\mathbf{z}}\| \quad (2.27)$$

kde

$$\bar{\mathbf{z}} = \mathbf{z} + \left[\nabla h(\mathbf{x}) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}, \mathbf{z}) \right]^{-1} \nabla h(\mathbf{x})^T \right]^{-1} h(\mathbf{x})$$

(b) Ak sú naviac Hessove matice funkcií f, h_i Lipschitzovsky spojité, t.j.

$$\begin{aligned}\|\nabla^2 f(\mathbf{x}_1) - \nabla^2 f(\mathbf{x}_2)\| &\leq L_0 \|\mathbf{x}_1 - \mathbf{x}_2\| \\ \|\nabla^2 h_i(\mathbf{x}_1) - \nabla^2 h_i(\mathbf{x}_2)\| &\leq L_i \|\mathbf{x}_1 - \mathbf{x}_2\|, \quad i = 1, \dots, p\end{aligned}$$

na nejakom okolí bodu $\hat{\mathbf{x}}$, potom existuje konšanta K_2 taká, že pre všetky $(\mathbf{z}, r) \in \mathbb{D}_2$ máme

$$\|\bar{\mathbf{z}} - \hat{\mathbf{z}}\| \leq \frac{K_2}{r^2} \|\mathbf{z} - \hat{\mathbf{z}}\|^2. \quad (2.28)$$

DÔKAZ: Dôkaz tvrdenia nájdeme v [1], str. 136. \square

Rovnako ako pre odhad prvého rádu aj pre odhad (2.22) platí, že za určitých dodatočných predpokladoch o \mathbf{z}^0 a $r^0 \geq \bar{r}$ vieme ukázať, že $\{\mathbf{z}^k\} \rightarrow \hat{\mathbf{z}}$ a $\{\mathbf{x}(\mathbf{z}^k)\} \rightarrow \hat{\mathbf{x}}$. Rýchlosť konvergencie je v prípade $\limsup_{k \rightarrow \infty} r^k = \hat{r} < \infty$ a $\mathbf{z}^k \neq \hat{\mathbf{z}}$ superlineárna a v prípade $\{r^k\} \rightarrow \infty$ a $\mathbf{z}^k \neq \hat{\mathbf{z}}$ kvadratická.

Pri odvodení tejto iterácie sme predpokladali, že minimalizácia funkcie $\mathcal{L}_{\text{PH}}(\cdot, \mathbf{z})$ je vykonaná exaktne, čiže máme $\nabla_x \mathcal{L}_{\text{PH}}(\cdot, \mathbf{z}) = 0$. Ak namiesto toho budeme predpokladať, že platí $\|\nabla_x \mathcal{L}_{\text{PH}}(\cdot, \mathbf{z})\| \leq \alpha$, $\alpha \geq 0$, potom môžeme uvažovať odhad

$$\begin{aligned}\mathbf{z}^{k+1} = \mathbf{z}^k + \left[\nabla h(\mathbf{x}^k) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}^k, \mathbf{z}^k) \right]^{-1} \nabla h(\mathbf{x}^k)^T \right]^{-1} \times \\ \left[h(\mathbf{x}^k) - \nabla h(\mathbf{x}^k) \left[\nabla_{xx}^2 \mathcal{L}_{\text{PH}}(\mathbf{x}^k, \mathbf{z}^k) \right]^{-1} \nabla_x \mathcal{L}_{\text{PH}}(\mathbf{x}^k, \mathbf{z}^k) \right].\end{aligned} \quad (2.29)$$

ktorý môžeme považovať za verziu odhadu (2.22) v prípade, ak minimalizačná procedúra nie je exaktná. Na tomto mieste je nutné spomenúť, že v praktických výpočtoch dosahuje (2.29) lepšie výsledky ako (2.22).

Zaujímavé je porovnanie výhod a nevýhod týchto odhadov (2.5) a (2.22). Z viet (2.2) a (2.3) vidíme, že oblasť konvergencie je v oboch prípadoch podobná, no dá sa ukázať, že kritická hodnota \bar{r} je v prípade odhadu prvého rádu (2.5) väčšia ako v prípade odhadu druhého rádu (2.22). Presnejšie, ak matica \mathbf{B} definovaná podľa (2.11) má zápornú vlastnú hodnotu a ak označíme \bar{e} najzápornejšiu z nich, potom iterácia prvého rádu vyžaduje $\bar{r} > -2\bar{e}$, zatiaľčo pre metódu druhého rádu stačí, aby $\bar{r} > -\bar{e}$. Naviac, iterácia druhého rádu má vyšší rát konvergencie. Na druhej strane, iterácia prvého rádu je výpočtovo jednoduchšia a v prípade konvexnej úlohy konverguje pre ľubovoľnú vstupnú dvojicu (\mathbf{z}^0, r^0) dokonca aj bez predpokladu diferencovateľnosti,

zatialčo metóda druhého rádu potrebuje druhé derivácie a konverguje len pre niektoré vstupné dvojice. Pre úlohu konvexného programovania je teda metóda prvého rádu robustnejšia.

Uvedené poznatky o metóde multiplikátorov Powella a Hestenesa aplikovanej na úlohu (\mathcal{PR}) využijeme pri odvodení a analýze tejto metódy aplikovanej na úlohu s ohraničeniami v tvare nerovností.

2.2 Metóda Rockafellara pre úlohu s ohraničeniami v tvare nerovníc

V tejto časti použijeme doposiaľ známe výsledky Powell-Hestenesovej metódy na odvodenie tzv. Rockafellarovej metódy pre úlohu v tvare

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g(\mathbf{x}) \geq 0 \end{aligned} \quad (\mathcal{PNR})$$

kde $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$, $g(\mathbf{x}) = (g_1(\mathbf{x}), \dots, g_m(\mathbf{x}))^\top$. Pripomeňme, že klasická Lagrangeova funkcia má pre túto úlohu tvar

$$L(\mathbf{x}, \mathbf{u}) = f(\mathbf{x}) - g(\mathbf{x})^\top \mathbf{u}, \quad L : \mathbb{R}^n \times \mathbb{R}_+^m \longrightarrow \mathbb{R}. \quad (2.30)$$

Tento problém je možné transformovať zavedením doplnkových premenných $\boldsymbol{\xi} = (\xi_1, \dots, \xi_m)^\top$ na ekvivalentnú úlohu

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}), \mathbf{x} \in \mathbb{R}^n \\ & \text{za podmienok} && \xi_i^2 - g_i(\mathbf{x}) = 0, \quad i = 1, \dots, m. \end{aligned} \quad (2.31)$$

Naviac máme, že $\hat{\mathbf{x}}$ je lokálnym (globálnym) minimom úlohy (\mathcal{PNR}) vtedy a len vtedy, ak $(\hat{\mathbf{x}}, \hat{\boldsymbol{\xi}}_1, \dots, \hat{\boldsymbol{\xi}}_m)$, kde $\hat{\boldsymbol{\xi}}_i = \sqrt{g_i(\hat{\mathbf{x}})}$, $i = 1, \dots, m$ je lokálnym (globálnym) minimom úlohy (2.31). Pomocou tejto transformácie odvodíme tzv. Rockafellarovu [40] rozšírenú Lagrangeovu funkciu pre úlohu (\mathcal{PNR}) .

Uvažujme najprv rozšírenú Lagrangeovu funkciu

$$\mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi}) = f(\mathbf{x}) + \sum_{i=1}^m \left[\mathbf{y}_i (\xi_i^2 - g_i(\mathbf{x})) + r (\xi_i^2 - g_i(\mathbf{x}))^2 \right]. \quad (2.32)$$

Pri aplikovaní algoritmu Powell-Hestenesa na úlohu (2.31) musíme minimalizovať funkciu (2.32) vzhľadom na $(\mathbf{x}, \boldsymbol{\xi}) \in \mathbb{R}^{n+m}$ pre rôzne, zafixované hodnoty multiplikátora \mathbf{y} . Ukážeme, že minimalizácia $\mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi})$ vzhľadom na $\boldsymbol{\xi}$ sa dá vykonať explicitne pre zafixovanú hodnotu vektora \mathbf{x} .

Kedže máme

$$\min_{\boldsymbol{\xi}} \mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi}) = f(\mathbf{x}) + \min_{\boldsymbol{\xi}} \sum_{i=1}^m \left[\mathbf{y}_i (\boldsymbol{\xi}_i^2 - g_i(\mathbf{x})) + \frac{r}{2} (\boldsymbol{\xi}_i^2 - g_i(\mathbf{x}))^2 \right],$$

vidíme, že minimalizácia $\mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi})$ vzhľadom na $\boldsymbol{\xi}_i$ je ekvivalentná s

$$\min_{\boldsymbol{\xi}_i} \left[\mathbf{y}_i (\boldsymbol{\xi}_i^2 - g_i(\mathbf{x})) + \frac{r}{2} (\boldsymbol{\xi}_i^2 - g_i(\mathbf{x}))^2 \right],$$

prípadne

$$\min_{\boldsymbol{\eta}_i \geq 0} \left[\mathbf{y}_i (\boldsymbol{\eta}_i - g_i(\mathbf{x})) + \frac{r}{2} (\boldsymbol{\eta}_i - g_i(\mathbf{x}))^2 \right]. \quad (2.33)$$

Kedže minimalizovaná funkcia v (2.33) je kvadratická v premennej $\boldsymbol{\eta}_i$, jej globálne minimum vzhľadom na $\boldsymbol{\eta}_i \in \mathbb{R}$ sa nadobúda v bode

$$\bar{\boldsymbol{\eta}}_i = g_i(\mathbf{x}) - \frac{\mathbf{y}_i}{r}.$$

Musíme uvažovať dve možnosti: ak $\bar{\boldsymbol{\eta}}_i \geq 0$, potom $\bar{\boldsymbol{\eta}}_i$ rieši minimalizačný problém (2.33) a teda $\hat{\boldsymbol{\eta}}_i = \bar{\boldsymbol{\eta}}_i$, v opačnom prípade máme $\hat{\boldsymbol{\eta}}_i = 0$. Sumárne dostávame pre $\hat{\boldsymbol{\eta}}_i$ vzťah

$$\hat{\boldsymbol{\eta}}_i = \max \left[0, g_i(\mathbf{x}) - \frac{\mathbf{y}_i}{r} \right],$$

a takisto máme

$$\hat{\boldsymbol{\eta}}_i - g_i(\mathbf{x}) = \max \left[-g_i(\mathbf{x}), -\frac{\mathbf{y}_i}{r} \right]. \quad (2.34)$$

Ak zavedieme pomocné označenia

$$g_i^+(\mathbf{x}, \mathbf{y}_i) = \max \left[-g_i(\mathbf{x}), -\frac{\mathbf{y}_i}{r} \right] = -\min \left[g_i(\mathbf{x}), \frac{\mathbf{y}_i}{r} \right], \quad (2.35)$$

a

$$g^+(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} g_1^+(\mathbf{x}, \mathbf{y}_1) \\ \vdots \\ g_m^+(\mathbf{x}, \mathbf{y}_m) \end{bmatrix},$$

potom z (2.33), (2.34) máme

$$\min_{\boldsymbol{\xi}} \mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi}) = f(\mathbf{x}) + g^+(\mathbf{x}, \mathbf{y})^T \mathbf{y} + \frac{r}{2} g^+(\mathbf{x}, \mathbf{y})^T g^+(\mathbf{x}, \mathbf{y}). \quad (2.36)$$

Rozšírená Lagrangeova funkcia pre úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$ je teda daná vzťahom

$$\mathcal{L}_R(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) + g^+(\mathbf{x}, \mathbf{y})^T \mathbf{y} + \frac{r}{2} g^+(\mathbf{x}, \mathbf{y})^T g^+(\mathbf{x}, \mathbf{y}).$$

Tento výraz je možné upraviť na ekvivalentný tvar

$$\mathcal{L}_R(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) + \frac{1}{2r} \sum_{i=1}^m \left[\max^2(0, \mathbf{y}_i - rg_i(\mathbf{x})) - \mathbf{y}_i^2 \right], \quad (2.37)$$

ktorý sa často používa v literatúre.

Uvedené výsledky možno sumarizovať takto: Úloha minimalizácie $\mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi})$ vzhľadom na $(\mathbf{x}, \boldsymbol{\xi}) \in \mathbb{R}^{n+m}$ je ekvivalentná minimalizácii $\mathcal{L}_R(\mathbf{x}, \mathbf{y})$ v premennej $\mathbf{x} \in \mathbb{R}^n$, a teda bod $(\mathbf{x}(\mathbf{y}), \boldsymbol{\xi}(\mathbf{y}))$ je riešením prvého z týchto problémov vtedy a len vtedy, ak $\mathbf{x}(\mathbf{y})$ je riešením druhého a platí

$$|\boldsymbol{\xi}_i(\mathbf{y})| = \sqrt{\max \left[0, g_i(\mathbf{x}(\mathbf{y})) - \frac{\mathbf{y}_i}{r} \right]}, \quad i = 1, \dots, m.$$

Algoritmus Powell-Hestenesa teda môžeme aplikovať na úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$ po jej pretransformovaní na ekvivalentný problém (2.31), no pri výpočte minima funkcie $\mathcal{L}(\mathbf{x}, \mathbf{y}, \boldsymbol{\xi})$ môžeme vynechať doplnkové premenné $\boldsymbol{\xi}_i, i = 1, \dots, m$, keďže namiesto tohto výpočtu môžeme ekvivalentne minimalizovať funkciu $\mathcal{L}_R(\mathbf{x}, \mathbf{y})$.

Pre funkciu

$$\Gamma(\mathbf{x}, \mathbf{y}) = \frac{1}{2r} \left[\max^2(0, \mathbf{y}_i - rg_i(\mathbf{x})) - \mathbf{y}_i^2 \right]$$

môžeme ľahko overiť platnosť Roodeho axióm z vety 2.1, kde použijeme $\mathbb{X} = \mathbb{R}^n$, $\mathbb{Y} = \mathbb{R}_+^m$ a $\mathbb{M} = \{\mathbf{x} \mid g(\mathbf{x}) \geq 0\}$. Rovnako ako v prípade rozšírenej funkcie Hestenesa a Powella platí

$$\nabla_x \mathcal{L}_R(\mathbf{x}, \boldsymbol{\mu}) = \nabla_x L(\mathbf{x}, \bar{\boldsymbol{\mu}}), \quad \text{pre } \bar{\boldsymbol{\mu}}_i = -\max [0, \boldsymbol{\mu}_i - rg_i(\mathbf{x})], \quad i = 1, \dots, m$$

a keďže $\nabla_x \mathcal{L}_R(\hat{\mathbf{x}}, \hat{\mathbf{y}}) = \nabla_x L(\hat{\mathbf{x}}, \hat{\mathbf{u}}) = 0$ a takisto $g(\hat{\mathbf{x}}) \geq 0$, $\hat{\mathbf{y}}^T g(\hat{\mathbf{x}}) = 0$, $\hat{\mathbf{y}} \geq 0$, potom $\hat{\mathbf{y}} = \hat{\mathbf{u}}$. Opäť dostávame rovnosť multiplikátorov v optimálnom bode.

Takmer všetky teoretické výsledky Powell-Hestenesovho algoritmu pre úlohu $(\mathcal{P}\mathcal{R})$ je možné mechanicky rozšíriť aj pre jeho aplikáciu na úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$. V tomto prípade budeme od optimálneho riešenia $\hat{\mathbf{x}}$ úlohy $(\mathcal{P}\mathcal{N}\mathcal{R})$ požadovať splnenie nasledovného predpokladu:

Predpoklad 2.2. Vektor $\hat{\mathbf{x}}$ je ostrým lokálnym minimom a regulárnym bodom problému $(\mathcal{P}\mathcal{N}\mathcal{R})$, pričom plati

$$\boldsymbol{\omega}^T \mathbf{L}(\hat{\mathbf{x}}, \hat{\mathbf{u}}) \boldsymbol{\omega} > 0$$

pre všetky $\boldsymbol{\omega} \neq 0$ splňajúce $\nabla g_i(\hat{\mathbf{x}})^T \boldsymbol{\omega} = 0$ pre všetky $i \in I_A(\hat{\mathbf{x}}) = \{i \mid g_i(\hat{\mathbf{x}}) = 0\}$, kde $\mathbf{L}(\cdot, \cdot)$ je definovaná v (2.30). Naviac, $\hat{\mathbf{u}}$ splňa podmienku ostrej komplementarity, čiže

$$\hat{u}_i > 0 \quad \text{pre všetky } i \in I_A(\hat{\mathbf{x}}).$$

Ak $\hat{\mathbf{x}}$ spĺňa predpoklad 2.2, potom lokálne minimum $(\hat{\mathbf{x}}, \sqrt{g_1(\hat{\mathbf{x}})}, \dots, \sqrt{g_m(\hat{\mathbf{x}})})$ problému (2.31) spĺňa predpoklad 2.1. Tento fakt umožňuje použiť algoritmus a jeho teoretické výsledky (napr. veta (2.2)) z časti (2.1) najprv na úlohu (2.31) a potom transformovaním na $(\mathcal{P}\mathcal{N}\mathcal{R})$.

V prípade úlohy $(\mathcal{P}\mathcal{R})$ sme definovali iteráciu multiplikátorov prvého rádu (2.5) ako

$$\mathbf{z}_j^{k+1} = \mathbf{z}_j^k + r^k h_j(\mathbf{x}^k), \quad j = 1, \dots, p,$$

podobne pre úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$ definujme

$$\mathbf{y}_i^{k+1} = \mathbf{y}_i^k + r^k g_i^+(\mathbf{x}^k, \mathbf{y}_i^k), \quad i = 1, \dots, m. \quad (2.38)$$

Kedžže máme (2.35), môžeme pre všetky $i = 1, \dots, m$ písat

$$\mathbf{y}_i^{k+1} = \mathbf{y}_i^k + r^k \max \left[-g_i(\mathbf{x}^k), -\frac{\mathbf{y}_i^k}{r} \right],$$

a nakoniec

$$\mathbf{y}_i^{k+1} = \max [0, \mathbf{y}_i^k - r^k g_i(\mathbf{x}^k)]. \quad (2.39)$$

Iterácia (2.39) je analógom k (2.5) pre úlohu $(\mathcal{P}\mathcal{N}\mathcal{R})$. Výraz (2.39) zároveň zaručí nezápornosť \mathbf{y}^k pre ľubovoľné $k > 1$.

Schematicky potom môžeme popísať tzv. Rockafellarov algoritmus takto:

Algoritmus (Rockafellar). Nech je daný rozšírený Lagrangeov multiplikátor \mathbf{y}^k a penalizačný parameter r^k . Vektor \mathbf{x}^k získame minimalizáciou funkcie $\mathcal{L}_R(\cdot, \mathbf{y}^k)$ na priestore \mathbb{R}^n . Ďalej položíme

$$\mathbf{y}_i^{k+1} = \max [0, \mathbf{y}_i^k - r^k g_i(\mathbf{x}^k)], \quad i = 1, \dots, m,$$

zvolíme nový penalizačný parameter $r^{k+1} \geq r^k$ a proces zopakujeme.

Tento algoritmus býva často nazývaný aj Powell-Hestenes-Rockafellarov [4].

2.2.1 Odvodenie odhadu druhého rádu

Na tomto mieste odvodíme rovnako ako pre úlohu (\mathcal{PR}) iteráciu druhého rádu k úlohe (\mathcal{PNR}) . K tomuto odvodeniu použijeme duálnu funkciu pre problém (\mathcal{PNR}) . Budeme postupovať rovnako ako v časti (2.1.1) (pre detaily pozri [1], [36]). Za platnosti predpokladu 2.2 definujeme duálnu funkciu

$$d_R(\mathbf{y}) = \min_{\|\mathbf{x} - \hat{\mathbf{x}}\| < \varepsilon} \mathcal{L}_R(\mathbf{x}, \mathbf{y}). \quad (2.40)$$

pre všetky (\mathbf{y}, r) patriace do množiny

$$\mathbb{D} = \{(\mathbf{y}, r) \mid \|\mathbf{y} - \hat{\mathbf{y}}\| < \delta r, r \geq \bar{r}\}, \quad (2.41)$$

kde δ, ε , a \bar{r} sú rovnaké ako vo Vete (2.2) aplikovanej na úlohu (2.31). Potom pre všetky $(\mathbf{y}, r) \in \mathbb{D}$ máme

$$\nabla_{\mathbf{y}} d_R(\mathbf{y}) = g^+(\mathbf{x}(\mathbf{y}), \mathbf{y}), \quad (2.42)$$

kde $\mathbf{x}(\mathbf{y})$ rieši (2.40). Ďalej odvodíme Hessovu maticu funkcie d_R . Ak $\mathbf{x}(\mathbf{y})$ patrí do množiny $\hat{\mathbb{S}}_{\mathbf{y}, r}$, kde

$$\hat{\mathbb{S}}_{\mathbf{y}, r} = \left\{ \mathbf{x} \mid g_i(\mathbf{x}) \neq \frac{\mathbf{y}_i}{r}, i = 1, \dots, m \right\},$$

potom je d_R dvakrát spojito diferencovateľná na nejakom okolí (\mathbf{y}, r) . Ak rozpíšeme výraz (2.42) po zložkách, dostaneme

$$\frac{\partial d_R(\mathbf{y})}{\partial \mathbf{y}_i} = \max \left[-g_i(\mathbf{x}(\mathbf{y}_i)), -\frac{\mathbf{y}_i}{r} \right], \quad i = 1, \dots, m,$$

potom ľahko spočítame aj druhé parciálne derivácie funkcie d_R . Pre všetky indexy i také, že $g_i(\mathbf{x}(\mathbf{y})) \geq \frac{\mathbf{y}_i}{r}$, máme

$$\frac{\partial^2 d_R(\mathbf{y})}{\partial \mathbf{y}_i \partial \mathbf{y}_j} = 0, \quad i \neq j, \quad (2.43)$$

$$\frac{\partial^2 d_R(\mathbf{y})}{\partial \mathbf{y}_i^2} = -\frac{1}{r}, \quad (2.44)$$

a pre zvyšné indexy i počítame druhé derivácie rovnako ako v (2.1.1), pričom považujeme $g_i(\mathbf{x}(\mathbf{y}))$ za rovnosti. Pre zjednodušenie sumárneho zápisu na chvíľu predpokladajme, že existuje index q taký, že platí $g_i(\mathbf{x}(\mathbf{y})) \geq \frac{\mathbf{y}_i}{r}$ pre $i = 1, \dots, q$ a

$g_i(\mathbf{x}(\mathbf{y})) < \frac{\mathbf{y}_i}{r}$ pre $i = q+1, \dots, m$, a označme $\mathbf{g}_{(m-q)}(\mathbf{x}) = (\mathbf{g}_{q+1}(\mathbf{x}), \dots, \mathbf{g}_m(\mathbf{x}))^\top$.
Potom

$$\nabla_{yy}^2 d_R = \begin{bmatrix} -\frac{1}{r} \mathbf{I}_q & 0 \\ 0 & \mathbf{H}(\mathbf{x}(\mathbf{y}), \mathbf{y}) \end{bmatrix}, \quad (2.45)$$

kde \mathbf{I}_q je $q \times q$ identická matica, a $\mathbf{H}(\mathbf{x}(\mathbf{y}), \mathbf{y})$ je matica rozmeru $(m-q) \times (m-q)$, pričom

$$\mathbf{H}(\mathbf{x}(\mathbf{y}), \mathbf{y}) = -\nabla g_{(m-q)}(\mathbf{x}(\mathbf{y})) \left[\nabla_{xx}^2 \mathcal{L}_R(\mathbf{x}(\mathbf{y}), \mathbf{y}) \right]^{-1} \nabla g_{(m-q)}(\mathbf{x}(\mathbf{y}))^\top,$$

Rovnako možno písť

$$\nabla_{yy}^2 d_R = - \left[\nabla g(\mathbf{x}(\mathbf{y})) \mathbf{D}_1 \left[\nabla_{xx}^2 \mathcal{L}_R(\mathbf{x}(\mathbf{y}), \mathbf{y}) \right]^{-1} \mathbf{D}_1 \nabla g(\mathbf{x}(\mathbf{y}))^\top - \mathbf{D}_2 \right], \quad (2.46)$$

pre

$$\mathbf{D}_1 = \begin{bmatrix} 0 & 0 \\ 0 & \mathbf{I}_{m-q} \end{bmatrix}, \quad \mathbf{D}_2 = \begin{bmatrix} \frac{1}{r} \mathbf{I}_q & 0 \\ 0 & 0 \end{bmatrix},$$

pričom \mathbf{I}_q a \mathbf{I}_{m-q} sú identické matice príslušných rozmerov. Následná iterácia má potom tvar

$$\mathbf{y}^{k+1} = \mathbf{y}^k - \left[\nabla_{yy}^2 d_R(\mathbf{y}^k) \right]^{-1} \nabla d_R(\mathbf{y}^k). \quad (2.47)$$

S využitím (2.42) a (2.45), resp. (2.46) vidíme, že

$$\mathbf{y}_i^{k+1} = 0 \quad \text{pre } i = 1, \dots, q, \quad (2.47a)$$

a

$$\mathbf{y}_{(m-q)}^{k+1} = \mathbf{y}_{(m-q)}^k - \left[\nabla g_{(m-q)}(\mathbf{x}^k) \left[\nabla_{xx}^2 \mathcal{L}_R(\mathbf{x}^k, \mathbf{y}^k) \right]^{-1} \nabla g_{(m-q)}(\mathbf{x}^k)^\top \right]^{-1} \mathbf{g}_{(m-q)}(\mathbf{x}^k), \quad (2.47b)$$

kde sme označili

$$\mathbf{y}_{(m-q)} = \begin{bmatrix} \mathbf{y}_{q+1} \\ \vdots \\ \mathbf{y}_m \end{bmatrix}.$$

Ak označíme

$$N_k = \left\{ i \mid g_i(\mathbf{x}(\mathbf{y}^k)) \geq \frac{\mathbf{y}_i}{r} \right\},$$

čiže N_k je množina indexov tých ohraničení, o ktorých predpokladáme, že budú neaktívne v $\hat{\mathbf{x}}$, potom iteráciu (2.47) môžeme s pomocou (2.47a) a (2.47b) opísať takto: Všetky Lagrangeove multiplikátory, ktoré zodpovedajú nerovniciam o ktorých

predpokladáme, že budú neaktívne v bode optima $\hat{\mathbf{x}}$, položíme rovné 0 (t.j. $\mathbf{y}_i^{k+1} = 0 \forall i \in N_k$), a zvyšné ohraničenia budeme považovať za rovnice a na základe tohto predpokladu odhadneme k nim prislúchajúce multiplikátory $\mathbf{y}_i^{k+1}, i \notin N_k$.

Niekoľko poznámok k metóde druhého rádu:

- (a) Vo všeobecnosti sa môže stať, že niektoré \mathbf{y}_i získané vzťahom (2.47) budú záporné, no z KKT podmienok vieme, že $\hat{\mathbf{y}} \geq 0$. Preto sa zdá byť rozumné použiť namiesto (2.47) upravenú iteráciu, ktorú definujeme ako

$$\bar{\mathbf{y}}^{k+1} = \mathbf{y}^k - [\nabla_{yy}^2 d_R(\mathbf{y}^k)]^{-1} \nabla d_R(\mathbf{y}^k)$$

a

$$\mathbf{y}^{k+1} = \begin{bmatrix} \max[0, \bar{\mathbf{y}}_1^{k+1}] \\ \vdots \\ \max[0, \bar{\mathbf{y}}_m^{k+1}] \end{bmatrix}, \quad (2.48)$$

čiže všetky záporné multiplikátory \mathbf{y}_i^{k+1} položíme rovné 0. Dá sa ukázať, že platí

$$\|\mathbf{y}^{k+1} - \hat{\mathbf{y}}\| \leq \|\bar{\mathbf{y}}^{k+1} - \hat{\mathbf{y}}\|,$$

a taktiež pre ľubovoľné (\mathbf{x}, \mathbf{y}) máme

$$\mathcal{L}_R(\mathbf{x}, \mathbf{y}) \leq \mathcal{L}_R(\mathbf{x}, \mathbf{y}^{k+1}),$$

z čoho plynie

$$d_R(\bar{\mathbf{y}}^{k+1}) \leq d_R(\mathbf{y}^{k+1}).$$

Vektor \mathbf{y}^{k+1} je teda bližšie k riešeniu $\hat{\mathbf{y}}$ ako $\bar{\mathbf{y}}^{k+1}$, a zároveň hodnotu duálnej funkcie nemôžeme zmeniť, ak vymeníme $\bar{\mathbf{y}}^{k+1}$ za \mathbf{y}^{k+1} . Tento poznatok je dôležitý pri dôkazoch konvergenčných viet, ako je Veta (2.3).

- (b) Podobne ako v prípade úlohy (\mathcal{PR}) môžeme dať iteráciu (2.47) do súvisu s riešením primárno-duálnej sústavy Newtonovou metódou. Vzťah (2.47) zodpovedá prípadu, keď je minimalizácia funkcie $\mathcal{L}_R(\cdot, \mathbf{y})$ presná. Rovnako ako v časti 2.1.1 môžeme definovať

$$\begin{aligned} \mathbf{y}^{k+1} = & \mathbf{y}^k - [\nabla_{yy}^2 d_R(\mathbf{y}^k)]^{-1} \times \\ & \left[\nabla_y d_R(\mathbf{y}^k) - \nabla g(\mathbf{x}^k) [\nabla_{xx}^2 \mathcal{L}_R(\mathbf{x}^k, \mathbf{y}^k)]^{-1} \nabla_x \mathcal{L}_R(\mathbf{x}^k, \mathbf{y}^k) \right]. \end{aligned} \quad (2.49)$$

zodpovedajúcu neexaktnej minimalizácii funkcie $\mathcal{L}_R(\cdot, \mathbf{y})$. Takisto možno pozorovať lepšie praktické výsledky oproti iterácii (2.47)

- (c) Výsledky odvodene pre iteráciu druhého rádu v časti 2.1.1 platia aj pre iterácie (2.39) a (2.47). Na zreteli musíme mať najmä globálnu konvergenciu iterácie (2.39) a iba lokálnu konvergenciu (2.47) pre úlohy konvexného programovania.

Podarilo sa nám odvodiť kvadratické penalizačné funkcie pre úlohy (\mathcal{PR}) a (\mathcal{PNR}) . V nasledujúcom teste poukážeme na niektoré teoretické nedostatky týchto metód a definujeme triedy všeobecných penalizačných funkcií.

2.3 Všeobecná penalizačná funkcia

Doposiaľ uvažované kvadratické penalizačné funkcie a k nim pridružené rozšírené Lagrangeove funkcie sú najrozšírenejšie pre túto triedu algoritmov. V istých špeciálnych prípadoch však môže byť žiaduce použiť inú ako kvadratickú penalizačnú funkciu. Tieto dôvody môžu byť napríklad takéto:

- (a) Existujú jednoduché príklady úloh (nekonvexného programovania), v ktorých je sice účelová funkcia na množine prípustných riešení zdola ohraničená, no príslušná rozšírená Lagrangeova funkcia túto vlastnosť nemá (na \mathbb{R}^n). Ako príklad uvažujme jednoduchú úlohu jednej premennej [1]

$$\begin{aligned} & \text{minimalizovať} \quad -x^{2\rho}, \quad x \in \mathbb{R} \\ & \text{za podmienky} \quad x = 0, \end{aligned} \tag{2.50}$$

pričom $\rho \in \mathbb{N}$. Hestenesova funkcia má potom tvar

$$\mathcal{L}_R(x, z) = -x^{2\rho} + xz + \frac{r}{2}x^2$$

a vidíme, že je zdola neohraničená pre ľubovoľné r , ak $\rho \geq 2$. Potom voľná minimalizácia tejto funkcie môže zlyhať s výnimkou, ak je štartovací bod dosťatočne blízko bodu lokálneho minima Powell-Hestenesovej funkcie. Tento nedostatok sa však dá napraviť voľbou inej penalizačnej funkcie (ich konkrétné tvary budeme uvažovať neskôr).

- (b) K úlohe (\mathcal{PNR}) sme jej transformáciou na úlohu (\mathcal{PR}) a následnou úpravou odvodili Rockafellarovu rozšírenú Lagrangeovu funkciu. Tento postup však spôsobuje, že druhá derivácia funkcie $\mathcal{L}_R(\cdot, \mathbf{y})$ je nespojité pre tie \mathbf{x} , ktoré spĺňajú $g_i(\mathbf{x}) = \frac{\mathbf{y}_i}{r}, i = 1, \dots, m$. Na druhej strane, minimalizačné metódy, ktoré prichádzajú do úvahy, vyžadujú spojitosť druhej derivácie na garanciu konvergencie.

V praktickej implementácii a riešení problémov sa však ukazuje, že pri použití Newtonovej, prípadne kvázinewtonovských metód tento nedostatok nemá negatívny vplyv na správanie sa algoritmu. Je tu však teoretická možnosť zlyhania a preto je potrebné sa ľahou zaoberať. V častiach, ktoré budú nasledovať, odvodíme triedu penalizačných, dvakrát spojito diferencovateľných funkcií.

- (c) Otázka rýchlosťi konvergencie je takisto dôležitá. Táto rýchlosť sa môže drasicky meniť v závislosti od použitej penalizačnej funkcie.

Všetky funkcie, ktoré budeme spomínať, budú splňať axiómy Roodeho vety 2.1, a takisto bude platiť, podobne ako v prípade funkcií Powell-Hestenesa a Rockafellara, rovnosť medzi klasickým a zovšeobecneným Lagrangeovým multiplikátorom v optimálnom bode ($\hat{z} = \hat{v}$ pre úlohu (\mathcal{PR}) a $\hat{y} = \hat{u}$ pre úlohu (\mathcal{PNR})).

Kvôli jednoduchosti začneme úlohou (\mathcal{PR}) a definujeme veľmi všeobecné podmienky na tvar penalizačných funkcií.

2.3.1 Penalizačné funkcie pre úlohu (\mathcal{PR})

K úlohe (\mathcal{PR}) definujme triedu penalizačných funkcií takto:

Trieda funkcií \mathcal{P}_{EQ} : Do tejto triedy zaradíme všetky funkcie $\phi : \mathbb{R} \rightarrow \mathbb{R}$ splňajúce tieto podmienky:

- (i) $\phi(\xi)$ je spojito diferencovateľná a ostro konvexná v \mathbb{R} ,
- (ii) $\phi(0) = 0$, $\phi'(0) = 0$,
- (iii) $\lim_{\xi \rightarrow \infty} \phi'(\xi) = \infty$, $\lim_{\xi \rightarrow -\infty} \phi'(\xi) = -\infty$.

K danej penalizačnej funkcií ϕ z triedy funkcií \mathcal{P}_{EQ} priradíme rozšírenú Lagrangeovu funkciu $\mathcal{L}_{EQ}(\mathbf{x}, \mathbf{z})$ predpisom

$$\mathcal{L}_{EQ}(\mathbf{x}, \mathbf{z}) = f(\mathbf{x}) + h(\mathbf{x})^T \mathbf{z} + \frac{1}{r} \sum_{j=1}^p \phi(rh_j(\mathbf{x})). \quad (2.51)$$

Metóda multiplikátorov potom pozostáva z voľnej minimalizácie funkcie $\mathcal{L}_{EQ}(\cdot, \mathbf{z}^k)$ na \mathbb{R}^n , ktorou získame vektor \mathbf{x}^k . Po tejto minimalizácii nasleduje iterácia multiplikátorov (v tomto prípade prvého rádu)

$$\mathbf{z}_j^{k+1} = \mathbf{z}_j^k + \phi'(rh_j(\mathbf{x}^k)), \quad j = 1, \dots, p. \quad (2.52)$$

Je možné odvodiť iteráciu multiplikátorov druhého rádu úplne analogickým postupom ako v časti 2.1.1, jej tvar bude rovnaký ako v (2.22) so zámenou $\mathcal{L}_{PH}(\cdot, \cdot) \rightarrow$

$\mathcal{L}_{\text{EQ}}(\cdot, \cdot)$. To isté platí aj pre definovanie iterácie v tvare (2.29), ktorá zodpovedá iterácii druhého rádu po neúplnej minimalizácii.

Zostáva ešte spomenúť príklady niektorých funkcií patriacich do triedy funkcií \mathcal{P}_{EQ} . Máme napríklad:

- (a) $\phi(\xi) = \frac{1}{2}\xi^2$,
- (b) $\phi(\xi) = \frac{1}{\nu}|\xi|^\nu$, $\nu > 1$,
- (c) $\phi(\xi) = \frac{1}{\nu}|\xi|^\nu + \frac{1}{2}\xi^2$, $\nu \in (1, 2)$,

(d) $\phi(\xi) = Q(\xi)$, Q je polynom stupňa 2ν , $\nu \in \mathbb{N}$, splňajúci $Q(0) = 0$ a $Q'(0) = 0$.

Môžeme si všimnúť, že pri použití (a) dostaneme Powell-Hestenesovu rozšírenú Lagrangeovu funkciu. Ak použijeme na definovanie rozšírenej Lagrangeovej funkcie funkciu (b), prípadne (d) pre ν dostatočne veľké, potom ju môžeme s úspechom aplikovať na riešenie problematickej úlohy (2.50). V literatúre sa často môžeme stretnúť aj s exponenciálnymi penalizačnými funkciemi, v ich prípade si však treba dať pozor pri implementácii. Veľmi ľahko môže dôjsť k pretečeniu vo floating-point aritmetike, preto sa pristupuje k ich extrapolácii polynomiálnymi funkciemi.

Takisto hodnota parametra ν funkcie (b) a (d) nesmie byť príliš veľká. Zvýšená rýchlosť konvergencie je v tomto prípade kompenzovaná zhoršujúcou sa podmienečnosťou Hessovej matice rozšírenej Lagrangeovej funkcie, čo môže mať negatívny vplyv na proces jej minimalizácie. Funkcia (c) dosahuje superlineárnu rýchlosť konvergencie, no vykazuje nespojitosť druhej derivácie. Existujú príklady úloh, v ktorých však dosahuje lepšie výsledky ako Powell-Hestenesova funkcia (a).

2.3.2 Penalizačné funkcie pre úlohu (\mathcal{PNR})

V prípade úlohy (\mathcal{PNR}) uvedieme jednu veľkú triedu funkcií, z ktorej vyberieme dve rôzne podskupiny funkcií, ktoré sa často vyskytujú a používajú v literatúre [4].

Trieda funkcií \mathcal{P}_{NEQ} : Do tejto triedy zaradíme všetky funkcie $P : \mathbb{R}^2 \rightarrow \mathbb{R}$ splňajúce tieto podmienky (použijeme označenie $P'(\xi, \eta) = \frac{\partial}{\partial \xi} P(\xi, \eta)$):

- (i) $P(\xi, \eta)$ je spojitá na $\mathbb{R} \times [0, \infty)$ a spojito diferencovateľná na $\mathbb{R} \times [0, \infty)$, $P(\cdot, 0)$ je spojito diferencovateľná v premennej ξ ,
- (ii) $P(\xi, \cdot)$ je konkávna na $[0, \infty]$ pre každé pevné ξ ,
- (iii) Pre každé $\eta \geq 0$ je $P(\cdot, \eta)$ konvexná v ξ na \mathbb{R} ,
- (iv) $P(0, \eta) = 0$ pre všetky $\eta \geq 0$,

- (v) $P'(0, \eta) = -\eta$ pre všetky $\eta \geq 0$,
- (vi) $\lim_{\xi \rightarrow \infty} P'(\xi, \eta) = 0$ pre všetky $\eta \geq 0$,
- (vii) $\lim_{\xi \rightarrow -\infty} P'(\xi, \eta) = -\infty$ pre všetky $\eta \geq 0$,
- (viii) $\inf_{\xi \in \mathbb{R}} P(\xi, \eta) > -\infty$ pre všetky $\eta \geq 0$.

Premennú ξ možno interpretovať ako výraz $rg_i(\mathbf{x})$, premennú η zasa považujme za multiplikátor \mathbf{y}_i , pre nejaké i . Funkcia $P(\xi, \eta)$ prechádza počiatkom a rastie do nekonečna pre $\xi \rightarrow -\infty$ (neprípustná oblasť, keďže $g_i(\mathbf{x}) < 0$), naviac sklon tejto funkcie rastie bez obmedzenia. Pre $\xi \rightarrow \infty$ funkcia postupne klesá k svojmu infimu (ktoré je konečné, a z konvexnosti funkcie vyplýva, že aj menšie alebo rovné 0). Multiplikátor η mení sklon funkcie P pri prechode počiatkom, kde je tento sklon rovný $-\eta$ (dôležité pre rovnosť medzi klasickým a rozšíreným vektorom Lagrangeových multiplikátorov v optimálnom bode).

Ku každej funkcií P priradíme rozšírenú Lagrangeovu funkciu predpisom

$$\mathcal{L}_{\text{NEQ}}(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) + \frac{1}{r} \sum_{i=1}^m P(rg_i(\mathbf{x}), \mathbf{y}_i). \quad (2.53)$$

Klasické metódy multiplikátorov môžeme prirodzene rozšíriť na použitie funkcie (2.53). Metóda prvého rádu teda bude zodpovedať voľnej minimalizácii funkcie $\mathcal{L}_{\text{NEQ}}(\cdot, \mathbf{y}^k)$ na \mathbb{R}^n , ktorou získame vektor \mathbf{x}^k . Po tejto minimalizácii nasleduje iterácia multiplikátorov prvého rádu

$$\mathbf{y}_j^{k+1} = -P'(rg_j(\mathbf{x}^k), \mathbf{y}_j), \quad i = 1, \dots, m. \quad (2.54)$$

Ak štartovací Lagrangeov multiplikátor spĺňa $\mathbf{y}^0 \geq 0$, potom z vlastností (iii), (vi), (vi) funkcie P máme, že $\mathbf{y}^k \geq 0$ pre všetky k .

Kedže máme

$$\nabla_{\mathbf{x}} \mathcal{L}_{\text{NEQ}}(\mathbf{x}, \mathbf{y}) = \nabla f(\mathbf{x}) - \sum_{i=1}^m P'(rg_i(\mathbf{x}), \mathbf{y}_i) \nabla g_i(\mathbf{x}), \quad (2.55)$$

tak z (2.54) vidíme, že platí

$$\nabla_{\mathbf{x}} \mathcal{L}_{\text{NEQ}}(\mathbf{x}^k, \mathbf{y}^k) = \nabla_{\mathbf{x}} L(\mathbf{x}^k, \mathbf{y}^{k+1}),$$

kde $L(\mathbf{x}, \mathbf{y})$ je klasická Lagrangeova funkcia definovaná vzťahom (2.30).

Prvá z podtried funkcií, ktorú budeme uvažovať pre problém (\mathcal{PNR}) , je transformovanou triedou \mathcal{P}_{EQ} . Získame ju rovnakým postupom, akým sme postupovali

pri odvodení Rockafellarovej funkcie z Powell-Hestenesovej funkcie v časti 2.2, čiže zavedením doplnkových premenných $\xi_i, i = 1, \dots, m$, transformáciou problému a následnou minimalizáciou príslušnej rozšírenej Lagrangeovej funkcie (2.51) priradenej k penalizačnej funkcií z triedy \mathcal{P}_{EQ} . Dostaneme tak odvodenú triedu funkcií \mathcal{P}_{NEQ} pre úlohu (\mathcal{PNR}) .

Trieda funkcií $\mathcal{P}_{\text{NEQ}}^1$: Do tejto triedy funkcií patria všetky funkcie $P : \mathbb{R}^2 \rightarrow \mathbb{R}$ definované vzťahom

$$P(\xi, \eta) = \begin{cases} \phi(\xi) - \xi\eta & \text{pre } \phi'(\xi) < \eta \\ \min_{\theta \in \mathbb{R}} \{\phi(\theta) - \theta\mu\} & \text{pre } \phi'(\xi) \geq \eta \end{cases}, \quad (2.56)$$

kde ϕ je penalizačná funkcia z triedy \mathcal{P}_{EQ} pre úlohu (\mathcal{PR}) . Existencia minima je zabezpečená vlastnosťami **(i)** a **(iii)** funkcie ϕ . Trieda $\mathcal{P}_{\text{NEQ}}^1$ teda zodpovedá metóde multiplikátorov pre úlohu (\mathcal{PNR}) po tom, čo ju pretransformujeme na úlohu (\mathcal{PR}) .

Použitím (2.56) dostaneme

$$\frac{\partial}{\partial \xi} P(\xi, \eta) = P'(\xi, \eta) = \begin{cases} \phi'(\xi) - \eta & \text{pre } \phi'(\xi) < \eta \\ 0 & \text{pre } \phi'(\xi) \geq \eta \end{cases},$$

a teda iterácia multiplikátorov (2.54) má pre triedu funkcií (2.56) tvar

$$\mathbf{y}_i^{k+1} = -P'(r g_i(\mathbf{x}^k), \mathbf{y}^k) = \max [0, \mathbf{y}_i^k - \phi'(r g_i(\mathbf{x}^k))].$$

Vezmieme napríklad $\phi(\xi) = \frac{1}{2}\xi^2$, čiže klasickú kvadratickú penalizačnú funkciu patriacu do triedy \mathcal{P}_{EQ} . Podľa (2.56) máme

$$P_R(\xi, \eta) = \begin{cases} \frac{1}{2}\xi^2 - \xi\eta & \text{pre } \xi < \eta \\ -\frac{\eta^2}{2} & \text{pre } \xi \geq \eta \end{cases},$$

a podľa (2.53) dostávame

$$\begin{aligned} \mathcal{L}_R(\mathbf{x}, \mathbf{y}) &= f(\mathbf{x}) + \frac{1}{r} \sum_{i=1}^m P_R(r g_i(\mathbf{x}), \mathbf{y}_i) \\ &= f(\mathbf{x}) + \frac{1}{2r} \sum_{i=1}^m \left[\max^2(0, \mathbf{y}_i - r g_i(\mathbf{x})) - \mathbf{y}_i^2 \right], \end{aligned}$$

čiže Rockafellarovu rozšírenú Lagrangeovu funkciu (2.37). Rovnako pre iteráciu multiplikátorov prvého rádu máme

$$\mathbf{y}_i^{k+1} = \max [0, \mathbf{y}_i^k - r g_i(\mathbf{x}^k)].$$

Rovnakým postupom získame ďalšie funkcie P pomocou ľubovoľnej funkcie $\phi \in \mathcal{P}_{\mathbf{EQ}}$, pre ktorú vieme nájsť minimum vo výraze (2.56) analyticky. Takisto je možné odvodiť iteráciu multiplikátorov druhého rádu opakovaním postupu z časti 2.2.1.

Kedže odvodenie celej triedy funkcií zodpovedalo postupu odvodenia Rockafelarovej penalizačnej funkcie z klasickej kvadratickej penalizačnej funkcie Powell-Hestenesa, metódy používajúce penalizačné funkcie z triedy $\mathcal{P}_{\mathbf{NEQ}}^1$ budú mať podobné vlastnosti ako sú uvedené v časti 2.2. Zároveň však zostane v platnosti aj nespojitosť druhých derivácií v bodoch, kde

$$\phi'(rg_i(\mathbf{x})) = \mathbf{y}_i, \quad i = 1, \dots, m.$$

Sformulujeme preto ešte jednu podtriedu triedy $\mathcal{P}_{\mathbf{NEQ}}$, ktorá bude zostrojená špeciálne pre úlohu (\mathcal{PNR}) , ktorá je v literatúre veľmi často spomínaná. Funkcie z tejto triedy budú mať spojité druhé derivácie.

Trieda funkcií $\mathcal{P}_{\mathbf{NEQ}}^2$: Do tejto triedy patria všetky funkcie $P : \mathbb{R}^2 \rightarrow \mathbb{R}$ tvaru

$$P(\xi, \eta) = \eta\psi(\xi),$$

kde $\psi : \mathbb{R} \rightarrow \mathbb{R}$ splňa nasledujúce požiadavky:

- (i) $\psi \in C^2$, ψ je ostro konvexná na \mathbb{R} ,
- (ii) $\psi(0) = 0$, $\psi'(0) = -1$,
- (iii) $\lim_{\xi \rightarrow -\infty} \psi(\xi) = \infty$, $\lim_{\xi \rightarrow \infty} \psi(\xi) > -\infty$,
- (iv) $\lim_{\xi \rightarrow -\infty} \psi'(\xi) = -\infty$, $\lim_{\xi \rightarrow \infty} \psi'(\xi) = 0$,

Penalizačné funkcie z tejto triedy sú lineárne v multiplikátore \mathbf{y} , zároveň vidíme, že z vlastnosti (i) vyplýva, že P má spojité druhé derivácie. Vlastnosť $\psi'(0) = -1$ za-bezpečí rovnosť medzi klasickým a rozšíreným optimálnym vektorom Lagrangeových multiplikátorov.

Typickým zástupcom funkcií z tejto triedy je exponenciálna penalizačná funkcia

$$\psi(\xi) = e^{-\xi} - 1,$$

konkrétnou tvorbou ďalších funkcií patriacich do $\mathcal{P}_{\mathbf{NEQ}}^2$ sa budeme zaoberať v ďalšej kapitole.

Rozšírená Lagrangeova funkcia prislúchajúca k triede penalizačných funkcií $\mathcal{P}_{\mathbf{NEQ}}^2$

je daná ako

$$\begin{aligned}\mathcal{L}_{\text{NEQ}}(\mathbf{x}, \mathbf{y}) &= f(\mathbf{x}) + \frac{1}{r} \sum_{i=1}^m P(rg_i(\mathbf{x}), \mathbf{y}_i) \\ &= f(\mathbf{x}) + \frac{1}{r} \sum_{i=1}^m \mathbf{y}_i \psi(rg_i(\mathbf{x})),\end{aligned}\tag{2.57}$$

a iterácia multiplikátorov prvého rádu je daná vzťahom

$$\mathbf{y}_i^{k+1} = -\mathbf{y}_i^k \psi'(rg_i(\mathbf{x}^k)), \quad i = 1, \dots, m.\tag{2.58}$$

Metódy rozšírených Lagrangeových funkcií používajúce funkciu (2.57) sa niekedy nazývajú metódami *nelineárneho škálovania* a parameter r škálovacím parametrom ([34]).

Je nutné poznamenať, že v prípade funkcií z triedy $\mathcal{P}_{\text{NEQ}}^2$ je nevyhnutné, aby $\mathbf{y}^0 > 0$. Potom na základe (2.58) a vlastností (i), (ii) a (iii) funkcie ψ platí $\mathbf{y}^k > 0$ pre všetky k . Pre úlohu konvexného programovania je možné pomocou teórie Fen-chelovej duality ukázať, že bod \mathbf{y}^{k+1} definovaný pomocou (2.58) maximalizuje penalizovanú duálnu funkciu úlohy (\mathcal{PNR}) odvodenú pomocou funkcie (2.57). Odhady multiplikátorov druhého rádu pre túto funkciu nie sú známe.

Napriek tomu, že teoretické výsledky pre funkcie z triedy $\mathcal{P}_{\text{NEQ}}^2$ nie sú také silné ako v prípade triedy $\mathcal{P}_{\text{NEQ}}^1$, ich algoritmické využitie takmer identické. Na druhej strane odstraňujú nedostatok funkcií z triedy $\mathcal{P}_{\text{NEQ}}^1$ v podobe nespojitosti druhej derivácie, a aj preto môžu byť použité ako súčasť metód, pre ktoré je táto vlastnosť nevyhnutná. Využijeme ich aj v nasledujúcej kapitole, v ktorej predstavíme algoritmus R. Polyaka a I. Grivu.

Kapitola 3

Nelineárne škálovanie a Fischerova metóda

V predošej kapitole sme sa venovali teoretickému popisu klasických metód rozšírených Lagrangeových funkcií. Každý krok týchto metód spočíval v minimalizácii rozšírenej Lagrangeovej funkcie na priestore primárnej premennej \mathbf{x} , po ktorej nasledoval odhad vektora zovšeobecnených Lagrangeových multiplikátorov \mathbf{y} . Penalizačný parameter r môže byť zafixovaný alebo zmenený na konci iterácie. Práve možnosť fixovania parametra r často zabráňuje zhoršovaniu podmienenosť Hessovej matice minimalizovanej funkcie. Aktívna prítomnosť Lagrangeových multiplikátorov je pre konvergenciu pri fixovanom r rozhodujúca. Ak sú splnené podmienky optimality druhého rádu (podmienky predpokladu 2.2 z časti 2.2), metódy konvergujú lineárne k (lokálnemu) optimálnemu riešeniu pri fixovanom, no dostatočne veľkom penalizačnom parametri $r \geq \bar{r}$ (veta 2.2).

Za účelom zlepšenia rýchlosťi konvergencie je nutné zvyšovať hodnotu penalizačného parametra po každej iterácii, čo môže viesť k výrazným numerickým ťažkostiam. Minimalizácia rozšírenej Lagrangeovej funkcie sa tak stáva náročnejšou. Tento problém študovali R. Polyak a I. Griva a publikovali v sérii článkov ([29], [30], [31], [32], [33], [34]), ktorých výsledkom bolo popísanie tzv. primárno-duálnej, nelineárne škálovacej metódy. Táto nahradzuje voľnú minimalizáciu rozšírenej Lagrangeovej funkcie a následný odhad multiplikátorov riešením tzv. primárno-duálnej nelineárnej sústavy rovníc, čo umožňuje neobmedzené zvyšovanie penalizačného parametra bez narušenia numerickej stability. V prípade špeciálnej voľby zmeny penalizačného parametra

je možné dosiahnuť superlineárnu rýchlosť konvergencie.

Kedže na riešenie spomínaného primárno-duálneho systému rovníc použijeme Newtonovu metódu, musí byť štartovací bod dostatočne blízko optimálnemu primárno-duálному riešeniu $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$. Preto výsledný algoritmus bude špeciálnym spojením klasického algoritmu rozšírených Lagrangeových funkcií a riešenia primárno-duálnej sústavy, kde využijeme „to najlepšie“ z oboch uvedených metód.

Táto kapitola je organizovaná nasledovne: Najprv sformulujeme základné predpoklady a zopakujeme metódu nelineárneho škálovania, potom odvodíme tzv. primárno-duálnu nelineárne škálovaciu metódu s dynamickou zmenou penalizačného parametra (PDNRD metóda, [30], [33]), a poukážeme na možné zlepšenia uvedeného prístupu (PDEPM metóda, [32]). Na záver ukážeme odlišný spôsob formulácie primárno-duálnej sústavy využitím tzv. Fischerovej funkcie [14], ktorá umožňuje prepísať KKT podmienky na systém rovníc [11], [12].

3.1 Metóda nelineárneho škálovania

Budeme sa zaoberať problémom konvexného programovania v tvare

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g(\mathbf{x}) \geq 0 \end{aligned} \tag{\mathcal{PNR}_C}$$

kde $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je konvexná, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ konkávna funkcia, a predpokladajme, že $f, g \in C^2$. Metódy uvedené v tejto časti je možné odvodiť aj pre ohraničenia typu

$$h(\mathbf{x}) = 0, \quad h : \mathbb{R}^n \rightarrow \mathbb{R}^p,$$

no tieto pre zjednodušenie výkladu vynecháme (odvodenie spočíva v mechanickom zopakování postupov, ktoré neskôr uvedieme). Niektoré vlastnosti uvedených metód platia aj bez predpokladu konvexnosti.

Pre jednoduchosť zápisov označme

$$I_A(\hat{\mathbf{x}}) = \{i \mid g_i(\hat{\mathbf{x}}) = 0\} = \{1, \dots, q\},$$

kde $q \leq \min\{n, m\}$ a takisto použime označenie $g_{(q)}(\mathbf{x}) = (g_1(\mathbf{x}), \dots, g_q(\mathbf{x}))^\top$ so štandardným predpokladom $\text{rank}(\nabla g_{(q)}(\hat{\mathbf{x}})) = q$. Lagrangeovu funkciu zapisujeme v tvare

$$L(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) - g(\mathbf{x})^\top \mathbf{y}, \quad L : \mathbb{R}^n \times \mathbb{R}_+^m \rightarrow \mathbb{R}. \tag{3.1}$$

V tejto kapitole budeme uvažovať, že platia nasledujúce predpoklady.

Predpoklad 3.1. Platí Slaterova podmienka, čiže existuje $\bar{\mathbf{x}}$ také, že $g_i(\bar{\mathbf{x}}) > 0, i = 1, \dots, m$.

Predpoklad 3.2. Vektor $\hat{\mathbf{x}}$ je ostrým globálnym minimom a regulárnym bodom problému $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$, pričom platí

$$\boldsymbol{\omega}^T \mathbf{L}(\hat{\mathbf{x}}, \hat{\mathbf{y}}) \boldsymbol{\omega} > 0$$

pre všetky $\boldsymbol{\omega} \neq 0$ splňajúce $\nabla g_i(\hat{\mathbf{x}})^T \boldsymbol{\omega} = 0$ pre $i \in \{1, \dots, q\}$, kde $\mathbf{L}(\cdot, \cdot)$ je definovaná v (3.1). Naviac, $\hat{\mathbf{y}}$ splňa podmienku ostrej komplementarity, čiže

$$\hat{y}_i > 0 \quad \text{pre všetky } i \in I_A(\hat{\mathbf{x}}).$$

Uvažujme rozšírenú Lagrangeovu funkciu s predpisom

$$\mathcal{L}_{\text{NR}}(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) + \frac{1}{r} \sum_{i=1}^m \mathbf{y}_i \psi(r g_i(\mathbf{x})), \quad (3.2)$$

kde transformačné funkcie ψ spĺňajú tieto podmienky:

- (i) $\psi'(\xi) < 0, \psi''(\xi) > 0, \psi \in C^2$,
- (ii) $\psi(0) = 0, \psi'(0) = -1$,
- (iii) $\psi(\xi) \geq \alpha \xi^2$, pre $\xi < 0$ a nejaké $\alpha > 0$,
- (iv) $-\psi'(\xi) \leq \frac{\beta}{\xi+1}, \psi''(\xi) \leq \frac{\gamma}{(\xi+1)^2}$, pre $\xi > 0$ a nejaké $\beta > 0, \gamma > 0$.

Funkcie ψ s uvedenými vlastnosťami tvoria podmnožinu funkcií patriacich do triedy $\mathcal{P}_{\text{NEQ}}^2$ definovanej v kapitole 2, kedže konkrétnie špecifikujeme rýchlosť ich rastu pre $\xi < 0$, resp. rýchlosť poklesu pre $\xi > 0$. Medzi najčastejšie používané transformačné funkcie ψ patria

$$(a) \psi_1(\xi) = e^{-\xi} - 1, \quad (b) \psi_2(\xi) = \frac{1}{1+\xi} - 1, \quad (c) \psi_3(\xi) = -\ln(1+\xi),$$

no tieto funkcie ešte nie sú vhodné pre praktické použitie. Funkcie ψ_2 a ψ_3 sú definované iba pre $\xi \in (-1, \infty)$ a exponenciálny rast funkcie ψ_1 môže byť až príliš veľký, preto je možné pristúpiť ku kvadratickej extrapolácii. Pre ľubovoľné $\tau \in (-1, 0]$ definujme

$$\psi_{p_i}(\xi) = \begin{cases} p_i(\xi) = a_i \xi^2 + b_i \xi + c_i & \xi \leq \tau, \\ \psi_i(\xi) & \xi > \tau. \end{cases} \quad (3.3)$$

Konštanty a_i, b_i, c_i polynómu $p_i(\xi)$ určíme podľa

$$\begin{aligned} a_i &= \frac{\psi_i''(\tau)}{2}, \\ b_i &= \psi_i'(\tau) - \tau\psi_i''(\tau), \\ c_i &= \psi_i(\tau) - \tau\psi_i'(\tau) + \frac{\tau^2\psi_i''(\tau)}{2}, \end{aligned}$$

kedže práve takáto voľba jednoznačne zabezpečí, že $\psi_{p_i} \in C^2$.

Algoritmus nelineárneho škálovania je potom klasickým zástupcom algoritmov rozšírených Lagrangeových funkcií.

Algoritmus (Nelineárne škálovanie). *Predpokladajme, že poznáme rozšírený Lagrangeov multiplikátor \mathbf{y}^k a penalizačný (škálovaci) parameter r^k . Vektor \mathbf{x}^{k+1} získame minimalizáciou funkcie $\mathcal{L}_{\text{NR}}(\cdot, \mathbf{y}^k)$ na priestore \mathbb{R}^n . Potom odhadneme multiplikátory vzťahom*

$$\mathbf{y}_i^{k+1} = -\mathbf{y}_i^k \psi'(r^k g_i(\mathbf{x}^{k+1})), \quad i = 1, \dots, m, \quad (3.4)$$

zvolíme nový penalizačný (škálovaci) parameter $r^{k+1} \geq r^k$ a proces zopakujeme.

Algoritmus je dobre definovaný vďaka vlastnostiam **(i)**, **(iii)** a **(iv)** funkcie ψ , za predpokladu konvexnosti úlohy $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ a predpokladu 3.1 (napr. [30], tvrdenie 1.).

Uvedený algoritmus vytvára postupnosť bodov $\mathbf{x}^k, \mathbf{y}^k$ podľa

$$\mathbf{x}^{k+1} : \nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^{k+1}, \mathbf{y}^k) = \nabla f(\mathbf{x}^{k+1}) + \sum_{i=1}^m \mathbf{y}_i^k \psi'(r^k g_i(\mathbf{x}^{k+1})) \nabla g_i(\mathbf{x}^{k+1}) = 0 \quad (3.5)$$

a

$$\mathbf{y}_i^{k+1} = -\mathbf{y}_i^k \psi'(r^k g_i(\mathbf{x}^{k+1})), \quad i = 1, \dots, m. \quad (3.6)$$

Ak označíme

$$\Psi'(r^k g(\mathbf{x}^{k+1})) = \text{diag} [\psi'(r^k g_i(\mathbf{x}^{k+1}))]_{i=1}^m = \begin{bmatrix} \psi'(r^k g_1(\mathbf{x}^{k+1})) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \psi'(r^k g_m(\mathbf{x}^{k+1})) \end{bmatrix},$$

potom môžeme (3.6) zapísť ako

$$\mathbf{y}^{k+1} = -\Psi'(r^k g(\mathbf{x}^{k+1})) \mathbf{y}^k. \quad (3.7)$$

Za platnosti predpokladu 3.2 algoritmus nelineárneho škálovania vytvára trajektóriu bodov $\{\mathbf{x}^k\}, \{\mathbf{y}^k\}$, ktorá konverguje k optimálnemu riešeniu lineárne pre

fixovaný prenalačný parameter r^k , a superlineárne, ak $r^k \rightarrow \infty$. Platia nasledovné ohraničenia

$$\|\mathbf{x}^{k+1} - \hat{\mathbf{x}}\| \leq \frac{K}{r^k} \|\mathbf{y}^k - \hat{\mathbf{y}}\|, \quad \|\mathbf{y}^{k+1} - \hat{\mathbf{y}}\| \leq \frac{K}{r^k} \|\mathbf{y}^k - \hat{\mathbf{y}}\|, \quad (3.8)$$

kde konštantá K nezávisí od r^k .

Nájdenie presnej hodnoty \mathbf{x}^{k+1} je vo všeobecnosti nemožné, preto sa uspokojujíme s jej aproximáciou $\tilde{\mathbf{x}}^{k+1}$. Ak nová approximativna dvojica $\tilde{\mathbf{x}}^{k+1}, \tilde{\mathbf{y}}^{k+1}$ generovaná algoritmom nelineárneho škálovania bude splňať

$$\tilde{\mathbf{x}}^{k+1} : \|\nabla_x \mathcal{L}_{\text{NR}}(\tilde{\mathbf{x}}^{k+1}, \tilde{\mathbf{y}}^k)\| \leq \frac{\sigma}{r^k} \|\Psi'(r^k g(\tilde{\mathbf{x}}^{k+1})) - \tilde{\mathbf{y}}^k\|, \quad (3.9)$$

$$\tilde{\mathbf{y}}^{k+1} = -\Psi'(r^k g(\tilde{\mathbf{x}}^{k+1})) \tilde{\mathbf{y}}^k, \quad (3.10)$$

potom sa dá ukázať ([31], s. 444-449), že platia podobné odhady ako vo vzťahu (3.8). Dvojicu $\tilde{\mathbf{x}}^{k+1}, \tilde{\mathbf{y}}^{k+1}$ vieme nájsť konečným počtom operácií.

Sústava rovníc (3.5), (3.7) bude základom pre odvodenie primárno-duálnej metódy Polyaka a Grivu ([32], [33], [34]).

3.2 Primárno-duálna metóda Polyaka a Grivu

Uvažujme už spomínanú sústavu rovníc

$$\nabla_x \mathcal{L}_{\text{NR}}(\bar{\mathbf{x}}, \mathbf{y}) = \nabla f(\bar{\mathbf{x}}) + \sum_{i=1}^m \mathbf{y}_i \psi'(r g_i(\bar{\mathbf{x}})) \nabla g_i(\bar{\mathbf{x}}) = \nabla_x \mathbf{L}(\bar{\mathbf{x}}, \bar{\mathbf{y}}) = 0, \quad (3.11)$$

$$\bar{\mathbf{y}} = -\Psi'(r g(\bar{\mathbf{x}})) \mathbf{y}. \quad (3.12)$$

Namiesto minimalizovania funkcie (3.1) a následným odhadom multiplikátorov podľa (3.6), budeme riešiť systém rovníc (3.11), (3.12). Na jeho riešenie aplikujeme Newtonovu metódu, pričom použijeme (\mathbf{x}, \mathbf{y}) ako štartovací bod.

Ak predpokladáme $\bar{\mathbf{x}} = \mathbf{x} + \Delta \mathbf{x}$, $\bar{\mathbf{y}} = \mathbf{y} + \Delta \mathbf{y}$, potom linearizáciou systému (3.11), (3.12), zanedbaním členov druhých a vyšších rádov a označením $\tilde{\mathbf{y}} = -\Psi'(r g(\mathbf{x})) \mathbf{y}$ dostaneme

$$\nabla_{xx}^2 \mathbf{L}(\mathbf{x}, \mathbf{y}) \Delta \mathbf{x} - \nabla g(\mathbf{x})^T \Delta \mathbf{y} = -\nabla_x \mathbf{L}(\mathbf{x}, \mathbf{y}), \quad (3.13)$$

$$r \psi''(r g_i(\mathbf{x})) \mathbf{y}_i \nabla g_i(\mathbf{x})^T \Delta \mathbf{x} + \Delta \mathbf{y}_i = \tilde{\mathbf{y}}_i - \mathbf{y}_i, \quad i = 1, \dots, m. \quad (3.14)$$

Ak označíme

$$\mathbf{Y} = \text{diag} [\mathbf{y}_i]_{i=1}^m = \begin{bmatrix} \mathbf{y}_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \mathbf{y}_m \end{bmatrix},$$

potom môžeme ekvivalentne písť

$$\begin{bmatrix} \nabla_{xx}^2 \mathcal{L}(\mathbf{x}, \mathbf{y}) & -\nabla g(\mathbf{x})^T \\ r\Psi''(rg(\mathbf{x}))\mathbf{Y}\nabla g(\mathbf{x}) & \mathbf{I}_m \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}(\mathbf{x}, \mathbf{y}) \\ \tilde{\mathbf{y}} - \mathbf{y} \end{bmatrix} \quad (3.15)$$

Označme

$$N(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} \nabla_{xx}^2 \mathcal{L}(\mathbf{x}, \mathbf{y}) & -\nabla g(\mathbf{x})^T \\ r\Psi''(rg(\mathbf{x}))\mathbf{Y}\nabla g(\mathbf{x}) & \mathbf{I}_m \end{bmatrix}, \quad (3.16)$$

potom z (3.15) máme

$$N(\mathbf{x}, \mathbf{y}) \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}(\mathbf{x}, \mathbf{y}) \\ \tilde{\mathbf{y}} - \mathbf{y} \end{bmatrix}. \quad (3.17)$$

Maticu $N_k(\mathbf{x}, \mathbf{y})$ budeme regulatizovať, aby sme zabezpečili jej regularitu pre ľubovoľnú dvojicu (\mathbf{x}, \mathbf{y}) :

$$N_k(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} \nabla_{xx}^2 \mathcal{L}(\mathbf{x}, \mathbf{y}) + \frac{1}{r^2} \mathbf{I}_n & -\nabla g(\mathbf{x})^T \\ r\Psi''(rg(\mathbf{x}))\mathbf{Y}\nabla g(\mathbf{x}) & \mathbf{I}_m \end{bmatrix}. \quad (3.18)$$

Táto konkrétna voľba regularizácie totiž nebude mať vplyv na rýchlosť konvergencie algoritmu. Predtým, ako popíšeme krok primárno-duálneho algoritmu, zadefinujme tzv. merit funkciu, ktorá bude určovať „vzdialenosť“ od riešenia $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$,

$$\nu(\mathbf{x}, \mathbf{y}) = \max \left\{ \|\nabla_x \mathcal{L}(\mathbf{x}, \mathbf{y})\|, -\min_{1 \leq i \leq m} \{g_i(\mathbf{x})\}, \sum_{i=1}^m |\mathbf{y}_i g_i(\mathbf{x})|, -\min_{1 \leq i \leq m} \{\mathbf{y}_i\} \right\}, \quad (3.19)$$

s vlastnosťou $\nu(\mathbf{x}, \mathbf{y}) \geq 0$ a $\nu(\hat{\mathbf{x}}, \hat{\mathbf{y}}) = 0$.

Jeden krok primárno-duálneho algoritmu potom spočíva v nasledovnom.

Algoritmus (Primárno-duálny). *Nech je daná primárno-duálna dvojica $\mathbf{x}^k, \mathbf{y}^k$. Jeden krok primárno-duálneho algoritmu potom spočíva v nasledovnom postupe:*

(1) Zo sústavy

$$N_k(\mathbf{x}^k, \mathbf{y}^k) \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) \\ \tilde{\mathbf{y}}^k - \mathbf{y}^k \end{bmatrix}$$

nájdeme primárno-duálne korektory $\Delta \mathbf{x}, \Delta \mathbf{y}$.

- (2) Položíme $\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta\mathbf{x}$, $\mathbf{y}^{k+1} = \mathbf{y}^k + \Delta\mathbf{y}$.
(3) Zmeníme penalizačný parameter r^{k+1} podľa pravidla

$$r^{k+1} = \frac{1}{\sqrt{\nu(\mathbf{x}^{k+1}, \mathbf{y}^{k+1})}}. \quad (3.20)$$

Uvedený postup je dobre definovaný, ak je matica $N_k(\mathbf{x}, \mathbf{y})$ regulárna pre ľubo-volné \mathbf{x}, \mathbf{y} . Ak by nebola, potom by musel existovať nenulový vektor $(\boldsymbol{\omega}, \boldsymbol{\chi})^T$ taký, že

$$N_k(\mathbf{x}, \mathbf{y}) \begin{bmatrix} \boldsymbol{\omega} \\ \boldsymbol{\chi} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}.$$

Vzhľadom na štruktúru systému (3.15) môžeme vyjadriť $\boldsymbol{\chi}$ vzťahom

$$\boldsymbol{\chi} = -r\Psi''(rg(\mathbf{x}))\mathbf{Y}\nabla g(\mathbf{x})\boldsymbol{\omega}.$$

Dosadením do prvej rovnice tejto sústavy máme

$$\left(\nabla_{xx}^2 L(\mathbf{x}, \mathbf{y}) + \frac{1}{r^2} \mathbf{I}_n + r\nabla g(\mathbf{x})^T \Psi''(rg(\mathbf{x}))\mathbf{Y}\nabla g(\mathbf{x}) \right) \boldsymbol{\omega} = M_k(\mathbf{x}, \mathbf{y})\boldsymbol{\omega} = 0.$$

Ak vezmeme do úvahy konvexnosť úlohy $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ a vlastnosť **(i)** funkcie ψ , dostaneme, že matica $M_k(\mathbf{x}, \mathbf{y})$ je kladne definitná, z čoho máme $\boldsymbol{\omega} = 0$ a následne $\boldsymbol{\chi} = 0$. Matica $N_k(\mathbf{x}, \mathbf{y})$ je teda regulárna.

Uvedený postup ukazuje, že vzhľadom na štruktúru uvedeného systému môžeme riešenie sústavy zjednodušiť. Najprv nájdeme primárny korektor $\Delta\mathbf{x}$ riešením

$$M_k(\mathbf{x}^k, \mathbf{y}^k)\Delta\mathbf{x} = -\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^k, \mathbf{y}^k),$$

potom položíme

$$\begin{aligned} \mathbf{x}^{k+1} &= \mathbf{x}^k + \Delta\mathbf{x}, \\ \mathbf{y}^{k+1} &= \tilde{\mathbf{y}}^k - r\Psi''(rg(\mathbf{x}^k))\mathbf{Y}\nabla g(\mathbf{x}^k)\Delta\mathbf{x}. \end{aligned}$$

Pre potreby ďalšej analýzy označme

$$\mathbf{w} = (\mathbf{x}, \mathbf{y}), \quad \mathbb{M}_\varepsilon = \{\mathbf{w} \mid \|\mathbf{w} - \hat{\mathbf{w}}\| \leq \varepsilon\}$$

Potom platí

Veta 3.1. Nech platí predpoklad 3.2 a nech sú Hessove matice funkcií f, g_i Lipschitzovsky spojité, t.j.

$$\begin{aligned}\|\nabla^2 f(\mathbf{x}_1) - \nabla^2 f(\mathbf{x}_2)\| &\leq L_0 \|\mathbf{x}_1 - \mathbf{x}_2\| \\ \|\nabla^2 g_i(\mathbf{x}_1) - \nabla^2 g_i(\mathbf{x}_2)\| &\leq L_i \|\mathbf{x}_1 - \mathbf{x}_2\|, \quad i = 1, \dots, m.\end{aligned}$$

Potom existuje ε_0 dostatočne malé tak, že pre ľubovoľnú dvojicu $\mathbf{w} = (\mathbf{x}, \mathbf{y}) \in \mathbb{M}_{\varepsilon_0}$ stačí jediný krok primárno-duálneho algoritmu na nájdenie novej primárno-duálnej dvojice $\bar{\mathbf{w}} = (\bar{\mathbf{x}}, \bar{\mathbf{y}})$ takej, že platí

$$\|\bar{\mathbf{w}} - \hat{\mathbf{w}}\| \leq C \|\mathbf{w} - \hat{\mathbf{w}}\|^{\frac{3}{2}},$$

kde C nezávisí od (\mathbf{x}, \mathbf{y}) .

DÔKAZ: Nájdeme v [33], s. 247-251. □

Vidíme, že pokiaľ sa štartovací bod nachádza v blízkosti optimálneho bodu, primárno-duálny algoritmus konverguje lokálne superlineárne. Dôležitým faktom v dôkaze je práve špeciálna voľba penalizačného parametra r^k . Konvergencia je však iba lokálna, preto spojením primárno-duálnej metódy a nelineárne-škálovacej metódy navrhнемe globálne konvergentný algoritmus.

Majme ľubovoľnú dvojicu $(\mathbf{x}^k, \mathbf{y}^k)$. Nový skúšobný bod $(\mathbf{x}_T^{k+1}, \mathbf{y}_T^{k+1})$ najprv nájdeme použitím primárno-duálneho algoritmu. Ak tento bod nezníži superlineárne hodnotu merit funkcie (t.j. $\nu(\mathbf{x}_T^{k+1}, \mathbf{y}_T^{k+1}) > \nu(\mathbf{x}^k, \mathbf{y}^k)^{1.5}$), znamená to, že bod $(\mathbf{x}^k, \mathbf{y}^k)$ ešte nie je dostatočne blízko optimálneho riešenia (nepatrí do $\mathbb{M}_{\varepsilon_0}$). V tomto prípade zamietneme skúšobný bod $(\mathbf{x}_T^{k+1}, \mathbf{y}_T^{k+1})$ a nový bod $(\mathbf{x}^{k+1}, \mathbf{y}^{k+1})$ nájdeme nelineárne škálovacím algoritmom - minimalizovaním rozšírenej Lagrangeovej funkcie a odhadom multiplikátorov. K tejto minimalizácii naviac môžeme použiť smer $\Delta \mathbf{x}$ nájdený primárno-duálnym algoritmom, keďže tento smer je vďaka kladnej definitnosti matice $M_k(\mathbf{x}^k, \mathbf{y}^k)$ spádový (t.j. $\nabla_x \mathcal{L}_{NR}(\mathbf{x}^k, \mathbf{y}^k)^T \Delta \mathbf{x} < 0$).

Spočiatku sa teda algoritmus správa rovnako ako nelineárne škálovací algoritmus a v tomto „móde“ vykoná niekoľko iterácií, generujúcich postupnosť bodov $\mathbf{x}^k, \mathbf{y}^k$, ktoré budú čoraz bližsie okoliu $\mathbb{M}_{\varepsilon_0}$ primárno-duálneho riešenia. Potom sa „prepne“ na primárno-duálny algoritmus, kde naplno využije jeho superlineárnu rýchlosť konvergencie (veta 3.1).

Môžeme si všimnúť, že k výraznému zväčšeniu penalizačného parametra r^k dochádza iba počas vykonávania primárno-duálnych krokov v záverečnej fáze algoritmu (vzťah (3.20)). Táto zmena nespôsobuje numerické ťažkosti ako v prípade voľnej minimalizácie, práve naopak: smer $(\Delta \mathbf{x}, \Delta \mathbf{y})$, ktorý získame riešením systému (3.18), sa čoraz viac podobá smeru, ktorý získame Newtonovou metódou aplikovanou na Lagrangeov systém rovníc zodpovedajúci aktívnym ohraničeniam. Algoritmus tak využíva najlepšie vlastnosti nelineárne-škálovacej metódy pre body vzdialené od riešenia $(\bar{\mathbf{x}}, \bar{\mathbf{y}})$ a primárno-duálnej metódy pre body v okolí \mathbb{M}_{ϵ_0} . Zároveň tak obchádza ich základné nedostatky.

Tento výsledný kombinovaný algoritmus Polyak a Griva nazývajú PDNRD algoritmus (primal-dual nonlinear-rescalling method with dynamic scaling parameter update, [33]). V článku [32] rozpracovali zlepšenie primárno-duálnej schémy zakladajúcej sa na identifikácii nulových multiplikátorov a zavedení vektora penalizačných parametrov, ktoré teraz uvedieme.

3.3 Vylepšená primárno-duálna schéma

Výsledkom spomínaného zlepšenia bude primárno-duálna metóda s asymptoticky kvadratickou rýchlosťou konvergencie. Základom bude identifikácia aktívnych ohraničení a nulových Lagrangeových multiplikátorov počas vykonávania algoritmu, k čomu poslúži fakt, že Lagrangeove multiplikátory prislúchajúce pasívnym ohraničeniam konvergujú k nule kvadraticky. Takisto zavedieme vektor škálovacích parametrov $\mathbf{p} = (\mathbf{p}_1, \dots, \mathbf{p}_m)^T$, ktorý bude v úzkom spojení s penalizačným parametrom r .

Budeme vychádzať zo sústavy

$$\nabla_x \mathcal{L}_{\text{NR}}(\bar{\mathbf{x}}, \mathbf{y}) = \nabla f(\bar{\mathbf{x}}) + \sum_{i=1}^m \mathbf{y}_i \psi'(\mathbf{p}_i g_i(\bar{\mathbf{x}})) \nabla g_i(\bar{\mathbf{x}}) = \nabla_x L(\bar{\mathbf{x}}, \bar{\mathbf{y}}) = 0, \quad (3.21)$$

$$\bar{\mathbf{y}} = -\Psi'(\mathbf{p} g(\bar{\mathbf{x}})) \mathbf{y}, \quad (3.22)$$

$$\mathbf{p}_i = \frac{r}{\mathbf{y}_i}, \quad i = 1, \dots, m, \quad (3.23)$$

kde

$$\Psi'(\mathbf{p} g(\mathbf{x})) = \text{diag} [\psi'(\mathbf{p}_i g_i(\mathbf{x}))]_{i=1}^m = \begin{bmatrix} \psi'(\mathbf{p}_1 g_1(\mathbf{x})) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \psi'(\mathbf{p}_m g_m(\mathbf{x})) \end{bmatrix}.$$

Definujme indexové množiny

$$I_+(\mathbf{x}, \mathbf{y}) = \{i \mid \mathbf{y}_i > \nu(\mathbf{x}, \mathbf{y})\}, \quad I_0(\mathbf{x}, \mathbf{y}) = \{i \mid \mathbf{y}_i < \nu(\mathbf{x}, \mathbf{y})\},$$

reprezentujúce množiny „veľkých“ a „malých“ Lagrangeových multiplikátorov. Rozdelíme systém (3.22) na dva podsystémy

$$\bar{\mathbf{y}}_i = -\mathbf{y}_i \psi'(\mathbf{p}_i g_i(\bar{\mathbf{x}})), \quad i \in I_+(\mathbf{x}, \mathbf{y}), \quad (3.24)$$

$$\bar{\mathbf{y}}_i = -\mathbf{y}_i \psi'(\mathbf{p}_i g_i(\bar{\mathbf{x}})), \quad i \in I_0(\mathbf{x}, \mathbf{y}). \quad (3.25)$$

Pri linearizácii systému rovníc (3.21), (3.24), (3.25) budeme prihliadať na odlišnosť týchto systémov. Uvedieme len výslednú linearizovanú schému, keďže jej odvodenie vyžaduje určité znalosti teórie Fenchelovej konvexnej transformácie. Označme

$$\left. \begin{array}{l} g_+(\mathbf{x}) = (g_i(\mathbf{x}))^\top \\ \mathbf{y}_+ = (\mathbf{y}_i)^\top \\ \mathbf{p}_+ = (\mathbf{p}_i)^\top \end{array} \right\} i \in I_+(\mathbf{x}, \mathbf{y}),$$

$$\left. \begin{array}{l} g_0(\mathbf{x}) = (g_i(\mathbf{x}))^\top \\ \mathbf{y}_0 = (\mathbf{y}_i)^\top \\ \mathbf{p}_0 = (\mathbf{p}_i)^\top \end{array} \right\} i \in I_0(\mathbf{x}, \mathbf{y}),$$

$$\tilde{\mathbf{y}}_0 = -\Psi'(\mathbf{p}_0 g_0(\mathbf{x})) \mathbf{y}_0, \quad (3.26)$$

potom dostávame (regularizovanú) sústavu (pre detaily odvodenia pozri [32])

$$\begin{bmatrix} \nabla_{xx}^2 L(\mathbf{x}, \mathbf{y}) + \frac{1}{r} \mathbf{I}_n & -\nabla g_+(\mathbf{x})^\top & -\nabla g_0(\mathbf{x})^\top \\ \nabla g_+(\mathbf{x}) & -\frac{\varphi''(1)}{r} \mathbf{I}_+ & 0 \\ r \Psi''(\mathbf{p}_0 g_0(\mathbf{x})) \mathbf{Y}_0 \nabla g_0(\mathbf{x}) & 0 & \mathbf{I}_0 \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y}_+ \\ \Delta \mathbf{y}_0 \end{bmatrix} = \begin{bmatrix} -\nabla_x L(\mathbf{x}, \mathbf{y}) \\ -g_+(\mathbf{x}) \\ \tilde{\mathbf{y}}_0 - \mathbf{y}_0 \end{bmatrix},$$

kde φ je záporne vzatá Fenchelova transformácia funkcie ψ . Opäť označíme

$$N_k(\mathbf{x}, \mathbf{y}_+, \mathbf{y}_0) = \begin{bmatrix} \nabla_{xx}^2 L(\mathbf{x}, \mathbf{y}) + \frac{1}{r} \mathbf{I}_n & -\nabla g_+(\mathbf{x})^\top & -\nabla g_0(\mathbf{x})^\top \\ \nabla g_+(\mathbf{x}) & -\frac{\varphi''(1)}{r} \mathbf{I}_+ & 0 \\ r \Psi''(\mathbf{p}_0 g_0(\mathbf{x})) \mathbf{Y}_0 \nabla g_0(\mathbf{x}) & 0 & \mathbf{I}_0 \end{bmatrix} \quad (3.27)$$

a popíšeme jeden krok modifikovanej primárno-duálnej metódy.

Algoritmus (Modifikovaný primárno-duálny). *Nech je daná primárno-duálna dvojica $\mathbf{x}^k, \mathbf{y}_+^k, \mathbf{y}_0^k$. Jeden krok modifikovaného primárno-duálneho algoritmu potom spočíva v nasledovnom postupe:*

(1) Zo sústavy

$$N_k(\mathbf{x}^k, \mathbf{y}_+^k, \mathbf{y}_0^k) \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y}_+ \\ \Delta \mathbf{y}_0 \end{bmatrix} = \begin{bmatrix} -\nabla_x L(\mathbf{x}^k, \mathbf{y}^k) \\ -g_+(\mathbf{x}^k) \\ \tilde{\mathbf{y}}_0^k - \mathbf{y}_0^k \end{bmatrix},$$

nájdeme primárno-duálne korektory $\Delta \mathbf{x}$, $\Delta \mathbf{y}_+$, $\Delta \mathbf{y}_0$.

(2) Položíme $\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta \mathbf{x}$, $\mathbf{y}_+^{k+1} = \mathbf{y}_+^k + \Delta \mathbf{y}_+$, $\mathbf{y}_0^{k+1} = \mathbf{y}_0^k + \Delta \mathbf{y}_0$

(3) Zmeníme penalizačný parameter r^{k+1} podľa pravidla

$$r^{k+1} = \frac{1}{\nu(\mathbf{x}^{k+1}, \mathbf{y}^{k+1})} \quad (3.28)$$

a položíme

$$\mathbf{p}_i^{k+1} = \frac{r^{k+1}}{\mathbf{y}_i^{k+1}}, \quad i = 1, \dots, m.$$

Oproti pôvodnému algoritmu si môžeme všimnúť aj pozmenené pravidlo zmeny penalizačného parametra.

Globálne konvergentný algoritmus opäť dostaneme spojením nelineárne škálovacieho algoritmu a modifikovaného primárno-duálneho algoritmu. Nelineárne škálovací algoritmus poslúži v úvodnej fáze na získanie bodov $\mathbf{x}^k, \mathbf{y}^k$ blízko optimálneho riešenia, modifikovaný primárno-duálny algoritmus potom spúšťame v záverečnej výpočtovej fáze. Tento algoritmus Polyak a Griva nazývajú PDEPM (primal-dual exterior point method, [32]). PDEMP vykazuje asymptoticky kvadratickú rýchlosť konvergencie.

Veta 3.2. Nech platí predpoklad 3.2 a nech sú Hessove matice funkcií f, g_i Lipschitzovy spojité, t.j.

$$\begin{aligned} \|\nabla^2 f(\mathbf{x}_1) - \nabla^2 f(\mathbf{x}_2)\| &\leq L_0 \|\mathbf{x}_1 - \mathbf{x}_2\| \\ \|\nabla^2 g_i(\mathbf{x}_1) - \nabla^2 g_i(\mathbf{x}_2)\| &\leq L_i \|\mathbf{x}_1 - \mathbf{x}_2\|, \quad i = 1, \dots, m. \end{aligned}$$

potom algoritmus PDEPM generuje globálne konvergentnú postupnosť bodov $\mathbf{x}^k, \mathbf{y}^k$ konvergujúcu k optimálnemu riešeniu $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$ s asymptoticky kvadratickou rýchlosťou.

DÔKAZ: Nájdeme v [32], s. 155-158. □

V poslednej časti tejto kapitoly ukážeme spôsob, ktorým môžeme previesť KKT systém na ekvivalentný systém, ktorý však bude obsahovať iba rovnice. Optimálny bod $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$ potom nájdeme riešením tohto systému.

3.4 Fischerova schéma

Doposiaľ sme sa zaobrali metódami, ktoré hľadajú sedlový bod (rozšírenej) Lagrangej funkcie prostredníctvom ich minimalizácie na priestore primárnej premennej, nasledovanej voľbou nového vektora Lagrangeových multiplikátorov, ktorý maximálizuje penalizovanú duálnu funkciu príslušnej duálnej úlohy. Metódy uvedené v častiach 3.2 a 3.3 tento bod hľadajú prostredníctvom riešenia primárno-duálnej sústavy, celková filozofia metód však zostáva zachovaná. V tejto časti spomenieme odlišný prístup, založený na transformácii KKT sústavy na ekvivalentnú sústavu rovníc.

Pripomeňme uvažovanú úlohu

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g(\mathbf{x}) \geq 0 \end{aligned} \quad (\mathcal{PNR}_C)$$

kde $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je konvexná, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ konkávna vektorová funkcia. Predpokladajme, že $f, g \in C^2$, a definujme pomocou

$$L(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) - g(\mathbf{x})^T \mathbf{y}$$

príslušnú Lagrangeovu funkciu. Ohraničenia typu

$$h(\mathbf{x}) = 0$$

neuvažujeme iba kvôli zjednodušeniu výkladu.

Nutné a postačujúce podmienky optimality pre úlohu (\mathcal{PNR}_C) v podobe Karush-Kuhn-Tuckerových podmienok majú tvar (veta 1.6)

$$\begin{aligned} \nabla f(\mathbf{x}) - \sum_{i=1}^m \mathbf{y}_i \nabla g_i(\mathbf{x}) &= 0, \\ g(\mathbf{x}) &\geq 0, \\ \mathbf{y}^T g(\mathbf{x}) &= 0, \\ \mathbf{y} &\geq 0, \end{aligned}$$

ktoré zapíšeme ako

$$\nabla_x L(\mathbf{x}, \mathbf{y}) = 0, \quad (3.29)$$

$$g(\mathbf{x}) \geq 0, \quad \mathbf{y} \geq 0, \quad g(\mathbf{x})^T \mathbf{y} = 0. \quad (3.30)$$

Vzťah (3.30) je podobný formulácií úloh o komplementarite, ktoré je možné pretransformovať na systém rovníc pomocou tzv. CP-funkcií (complementarity problem functions, [27]).

Definícia 3.1 (CP-funkcia). *Funkciu $\phi : \mathbb{R}^2 \rightarrow \mathbb{R}$ nazveme CP-funkciou, ak platí*

$$\phi(\alpha, \beta) = 0 \iff \alpha \geq 0, \beta \geq 0, \alpha\beta = 0. \quad (3.31)$$

Z uvedenej definície je zrejmé, že pomocou CP-funkcií môžeme transformovať systém (3.29), (3.30) na ekvivalentný systém

$$\nabla_x L(\mathbf{x}, \mathbf{y}) = 0, \quad (3.32)$$

$$\phi(g_i(\mathbf{x}), \mathbf{y}_i) = 0, \quad i = 1, \dots, m. \quad (3.33)$$

V minulosti bolo navrhnutých viacero takýchto funkcií (spomínané napr. v [13]), no v poslednej dobe sa teší popularite najmä CP-funkcia zavedená Fischerom ([14], [15]).

Veta 3.3. *Nech je funkcia ϕ_F definovaná vzťahom*

$$\phi_F(\alpha, \beta) = \alpha + \beta - \sqrt{\alpha^2 + \beta^2}.$$

Potom ϕ_F je CP-funkcia.

DÔKAZ: (\implies) Nech platí $\phi_F(\alpha, \beta) = 0$. Ak $\alpha + \beta < 0$, potom $\phi_F(\alpha, \beta) < 0$ pre ľubovoľné α, β spĺňajúce uvedenú nerovnosť. Predpokladajme teda, že $\alpha + \beta \geq 0$. Potom namiesto výrazu $\phi_F(\alpha, \beta) = 0$ môžeme ekvivalentne písť

$$(\alpha + \beta)^2 = \alpha^2 + \beta^2,$$

z čoho plynie $\alpha\beta = 0$. Využitím výrazov $\alpha + \beta \geq 0$ a $\alpha\beta = 0$ už ľahko dostaneme, že musí platiť $\alpha \geq 0$ a takisto $\beta \geq 0$.

(\impliedby) Ak platí $\alpha\beta = 0$, potom môžeme písť

$$\begin{aligned} \phi_F(\alpha, \beta) &= \alpha + \beta - \sqrt{\alpha^2 + \beta^2 + 2\alpha\beta} = \alpha + \beta - \sqrt{(\alpha + \beta)^2} \\ &= \alpha + \beta - |\alpha + \beta|. \end{aligned}$$

Kedže predpokladáme $\alpha \geq 0, \beta \geq 0$, potom $\phi_F(\alpha, \beta) = 0$, čo sme chceli dokázať. \square

Funkcia ϕ_F je spojité a pre jej parciálne derivácie platí

$$\frac{\partial \phi_F(\alpha, \beta)}{\partial \alpha} = 1 - \frac{\alpha}{\sqrt{\alpha^2 + \beta^2}}, \quad \frac{\partial \phi_F(\alpha, \beta)}{\partial \beta} = 1 - \frac{\beta}{\sqrt{\alpha^2 + \beta^2}}. \quad (3.34)$$

Problém so spojitosťou prvých parciálnych derivácií (3.34) v bode $(0, 0)$ je možné obísť zavedením regularizovanej Fischerovej funkcie

$$\phi_{F\mu}(\alpha, \beta) = \alpha + \beta - \sqrt{\alpha^2 + \beta^2 + 2\mu} \quad (3.35)$$

s vlastnosťou

$$\phi_{F\mu}(\alpha, \beta) = 0 \iff \alpha > 0, \beta > 0, \alpha\beta = \mu, \quad (3.36)$$

pre $\mu > 0$, ktorú dokážeme rovnako ako vo vete 3.3. Označme

$$\Phi_{F\mu}(g(\mathbf{x}), \mathbf{y}) = \begin{bmatrix} \phi_{F\mu}(g_1(\mathbf{x}), \mathbf{y}_1) \\ \vdots \\ \phi_{F\mu}(g_m(\mathbf{x}), \mathbf{y}_m) \end{bmatrix},$$

potom budeme approximovať systém (3.32), (3.33) systémom

$$\nabla_x L(\mathbf{x}, \mathbf{y}) = 0 \quad (3.37)$$

$$\Phi_{F\mu}(g(\mathbf{x}), \mathbf{y}) = 0. \quad (3.38)$$

Jedným zo spôsobov riešenia tohto systému je minimalizácia jeho normy. V tomto prípade vznikajú menšie problémy aj pri ostro konvexných úlohách [12], preto na jeho riešenie aplikujeme Newtonovu metódu. Linearizovaním uvedenej sústavy a zanedbaním členov druhého a vyššieho rádu dostávame (predpokladáme $\bar{\mathbf{x}} = \mathbf{x} + \Delta\mathbf{x}$, $\bar{\mathbf{y}} = \mathbf{y} + \Delta\mathbf{y}$)

$$\begin{bmatrix} \nabla_{xx}^2 L(\mathbf{x}, \mathbf{y}) & -\nabla g(\mathbf{x})^T \\ \mathbf{D}_\alpha \nabla g(\mathbf{x}) & \mathbf{D}_\beta \end{bmatrix} \begin{bmatrix} \Delta\mathbf{x} \\ \Delta\mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x L(\mathbf{x}, \mathbf{y}) \\ -\Phi_{F\mu}(g(\mathbf{x}), \mathbf{y}) \end{bmatrix}. \quad (3.39)$$

kde používame označenie

$$\mathbf{D}_\alpha = \text{diag} [\phi'_{F\mu;\alpha}(g(\mathbf{x}), \mathbf{y})]_{i=1}^m = \begin{bmatrix} \phi'_{F\mu;\alpha}(g_1(\mathbf{x}), \mathbf{y}_1) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \phi'_{F\mu;\alpha}(g_m(\mathbf{x}), \mathbf{y}_m) \end{bmatrix},$$

$$\mathbf{D}_\beta = \text{diag} [\phi'_{F\mu;\beta}(g(\mathbf{x}), \mathbf{y})]_{i=1}^m = \begin{bmatrix} \phi'_{F\mu;\beta}(g_1(\mathbf{x}), \mathbf{y}_1) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \phi'_{F\mu;\beta}(g_m(\mathbf{x}), \mathbf{y}_m) \end{bmatrix},$$

pričom

$$\phi'_{F\mu;\alpha}(g_i(\mathbf{x}), \mathbf{y}_i) = \frac{\partial \phi_{F\mu}(\alpha, \beta)}{\partial \alpha} \Big|_{\alpha=g_i(\mathbf{x}), \beta=\mathbf{y}_i},$$

$$\phi'_{F\mu;\beta}(g_i(\mathbf{x}), \mathbf{y}_i) = \frac{\partial \phi_{F\mu}(\alpha, \beta)}{\partial \beta} \Big|_{\alpha=g_i(\mathbf{x}), \beta=\mathbf{y}_i}.$$

Označme

$$N_\gamma(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} \nabla_{xx}^2 L(\mathbf{x}, \mathbf{y}) + \gamma \mathbf{I}_n & -\nabla g(\mathbf{x})^T \\ \mathbf{D}_\alpha \nabla g(\mathbf{x}) & \mathbf{D}_\beta \end{bmatrix}, \quad \gamma > 0 \quad (3.40)$$

regularizovanú maticu sústavy (3.39). Newtonovské smery $(\Delta \mathbf{x}, \Delta \mathbf{y})$ budú touto sústavou dobre definované, ak $N_\gamma(\mathbf{x}, \mathbf{y})$ bude regulárna matica pre ľubovoľné (\mathbf{x}, \mathbf{y}) . Ak by nebola regulárna, potom by muselo platiť

$$N_\gamma(\mathbf{x}, \mathbf{y}) \begin{bmatrix} \boldsymbol{\omega} \\ \boldsymbol{\chi} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

pre nenulový vektor $(\boldsymbol{\omega}, \boldsymbol{\chi})^T$. Z druhej rovnice pre $\boldsymbol{\chi}$ dostávame

$$\boldsymbol{\chi} = -\mathbf{D}_\beta^{-1} \mathbf{D}_\alpha \nabla g(\mathbf{x}) \boldsymbol{\omega}$$

a dosadením do prvej rovnice máme

$$\left(\nabla_{xx}^2 L(\mathbf{x}, \mathbf{y}) + \gamma \mathbf{I}_n + \nabla g(\mathbf{x})^T \mathbf{D}_\beta^{-1} \mathbf{D}_\alpha \nabla g(\mathbf{x}) \right) \boldsymbol{\omega} = M_\gamma(\mathbf{x}, \mathbf{y}) \boldsymbol{\omega} = 0.$$

Matica $M_\gamma(\mathbf{x}, \mathbf{y})$ je kladne definitná (konvexnosť úlohy (\mathcal{PNR}_C) a kladnosť prvkov diagonálnych matíc $\mathbf{D}_\alpha, \mathbf{D}_\beta$), čiže $\boldsymbol{\omega} = 0$, a následne $\boldsymbol{\chi} = 0$. Matica $N_\gamma(\mathbf{x}, \mathbf{y})$ je regulárna.

Základnú ideu hľadania optimálneho riešenia $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$ potom môžeme zhrnúť takto:

Algoritmus (Fischerov). *Nech je daná dvojica vektorov $\mathbf{x}^k, \mathbf{y}^k$. Jeden krok Fischerovo algoritmu potom spočíva v nasledovnom postupe:*

(1) Zo sústavy

$$N_\gamma(\mathbf{x}^k, \mathbf{y}^k) \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x L(\mathbf{x}^k, \mathbf{y}^k) \\ -\Phi_{F\mu}(g(\mathbf{x}^k), \mathbf{y}^k) \end{bmatrix}$$

nájdeme Newtonovské smery $\Delta \mathbf{x}, \Delta \mathbf{y}$.

(2) Položíme $\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta \mathbf{x}$, $\mathbf{y}^{k+1} = \mathbf{y}^k + \Delta \mathbf{y}$ a zvolíme $\gamma^{k+1} \leq \gamma^k$.

Uvedený algoritmus však konverguje len pre body $(\mathbf{x}^k, \mathbf{y}^k)$ patriace do nejakého okolia optimálneho riešenia $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$, pričom veľkosť tohto okolia závisí od dát úlohy. Pri rozšírení algoritmu na globálny sa ponúkajú dve možnosti

- (a) Krok (2) uvedeného algoritmu nahradíme

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \lambda^k \Delta \mathbf{x}, \quad \mathbf{y}^{k+1} = \mathbf{y}^k + \lambda^k \Delta \mathbf{y},$$

kde λ^k získame vyhľadávaním na lúči normy riešeného systému. Ak označíme $\mathbf{w} = (\mathbf{x}, \mathbf{y})$, $\mathbf{s} = (\Delta \mathbf{x}, \Delta \mathbf{y})$ a

$$F(\mathbf{w}) = \begin{bmatrix} \nabla_{\mathbf{x}} L(\mathbf{x}, \mathbf{y}) \\ \Phi_{F\mu}(g(\mathbf{x}), \mathbf{y}) \end{bmatrix},$$

potom λ^k získame približným riešením úlohy

$$\lambda^k = \arg \min_{\lambda > 0} \left\{ \|F(\mathbf{w} + \lambda \mathbf{s})\| \right\}.$$

- (b) Na získanie potrebných bodov $(\mathbf{x}^k, \mathbf{y}^k)$ môžeme využiť napríklad nelineárne škálovací algoritmus. Fischerovu metódu potom spustíme až v čase, keď tieto body budú ležať v požadovanom okolí optimálneho riešenia $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$.

Ani jednu z uvedených modifikácií nepodporíme dôkazom konvergencie, no pokúsime sa ich otestovať rozličnými numerickými experimentami.

Kapitola 4

Numerické experimenty

Záverečnú kapitolu tejto práce venujeme numerickým experimentom, ktorých cieľom bude vzájomné porovnanie rôznych metód k riešeniu úlohy konvexného programovania v tvare

$$\begin{aligned} & \text{minimalizovať} && f(\mathbf{x}) \\ & \text{za podmienok} && g(\mathbf{x}) \geq 0 \end{aligned} \tag{\mathcal{PNR}_c}$$

kde $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je konvexná, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ je konkávna vektorová funkcia, $g(\mathbf{x}) = (g_1(\mathbf{x}), \dots, g_m(\mathbf{x}))^\top$. Za týmto účelom využijeme náhodne generované úlohy konvexného bikvadratického (kvadratického) programovania, a takisto vybrané úlohy zo zbierky testovacích príkladov CUTER [18].

Kapitola je rozdelená do troch logických celkov. V prvom popíšeme spôsob náhodného generovania úloh, v druhom sa budeme venovať implementácií uvažovaných algoritmov, a v treťom uvedieme výsledky navrhnutých experimentov, ktoré stručne okomentujeme.

4.1 Generátor úloh

Dôležitým predpokladom pre tvorbu automatického generátora úloh (\mathcal{PNR}_c) je voľba konkrétnej triedy úloh, pre ktorú budeme môcť takýto generátor ľahko implementovať. My sme si zvolili triedu úloh bikvadratického programovania. Konkrétna

voľba funkcií f, g teda bude

$$f(\mathbf{x}) = \frac{1}{4}(\mathbf{x}^T \mathbf{D} \mathbf{x})^2 + \frac{1}{2} \mathbf{x}^T \mathbf{G} \mathbf{x} + \mathbf{h}^T \mathbf{x},$$

$$g_i(\mathbf{x}) = \begin{cases} \frac{1}{2} \mathbf{x}^T \mathbf{G}_i \mathbf{x} + \mathbf{h}_i^T \mathbf{x} - \mathbf{t}_i, & i = 1, \dots, q, \\ \mathbf{a}_i^T \mathbf{x} - \mathbf{b}_i, & i = 1, \dots, m-q. \end{cases} \quad (4.1)$$

pre nejaké kladne definitné matice \mathbf{D}, \mathbf{G} (\mathbf{D} diagonálna) a záporne definitné matice $\mathbf{G}_i, i = 1, \dots, q$, kde predpokladáme $0 \leq q \leq m$. Vektory $\mathbf{h}, \mathbf{h}_i, \mathbf{t}_i, \mathbf{a}_i, \mathbf{b}_i$ volíme „ľubovoľne“ (drobné obmedzenie špecifikujeme neskôr). Z riadkových vektorov \mathbf{a}_i^T utvoríme maticu \mathbf{A} . Pre takto zvolené funkcie a matice bude úloha $(\mathcal{P}\mathcal{N}\mathcal{R}_C)$ rýdzou konvexná. Jej primárno-duálne optimálne riešenie $(\hat{\mathbf{x}}, \hat{\mathbf{u}})$ je potom jednoznačne determinované sústavou KKT podmienok, ktoré nadobúdajú tvar

$$(\hat{\mathbf{x}}^T \mathbf{D} \hat{\mathbf{x}}) \mathbf{D} \hat{\mathbf{x}} + \mathbf{G} \hat{\mathbf{x}} + \mathbf{h} - \mathbf{A}^T \hat{\mathbf{u}}_{(m-q)} - \sum_{i=1}^q \hat{\mathbf{u}}_i (\mathbf{G}_i \hat{\mathbf{x}} + \mathbf{h}_i) = 0 \quad (4.2)$$

$$\frac{1}{2} \hat{\mathbf{x}}^T \mathbf{G}_i \hat{\mathbf{x}} + \mathbf{h}_i^T \hat{\mathbf{x}} \geq \mathbf{t}_i, \quad i = 1, \dots, q, \quad (4.3)$$

$$\mathbf{u}_i \left(\frac{1}{2} \hat{\mathbf{x}}^T \mathbf{G}_i \hat{\mathbf{x}} + \mathbf{h}_i^T \hat{\mathbf{x}} - \mathbf{t}_i \right) = 0, \quad i = 1, \dots, q, \quad (4.4)$$

$$\mathbf{A} \hat{\mathbf{x}} \geq \mathbf{b}, \quad (4.5)$$

$$\hat{\mathbf{u}}_{(m-q)}^T (\mathbf{A} \hat{\mathbf{x}} - \mathbf{b}) = 0, \quad (4.6)$$

$$\hat{\mathbf{u}} \geq 0, \quad (4.7)$$

kde označujeme $\mathbf{u}_{(m-q)} = (\mathbf{u}_{q+1}, \dots, \mathbf{u}_m)^T$ a $\mathbf{u} = (\mathbf{u}_1, \dots, \mathbf{u}_q, \mathbf{u}_{(m-q)})^T$. Potrebujeme ešte zabezpečiť lineárnu nezávislosť gradientov $\nabla g_i(\hat{\mathbf{x}})$ prislúchajúcich aktívnym ohraničeniam. Predpokladajme, že existujú $1 \leq q_1 \leq q, 1 \leq q_2 \leq m-q, q_1 + q_2 \leq n$ také, že prvých q_1 kvadratických ohraničení a prvých q_2 lineárnych ohraničení je aktívnych v $\hat{\mathbf{x}}$. Potom musí platiť

$$\text{rank}(\nabla g_{(q_1+q_2)}(\hat{\mathbf{x}})) = \min\{q_1 + q_2, n\}, \quad \nabla g_{(q_1+q_2)}(\hat{\mathbf{x}}) = \begin{bmatrix} (\mathbf{G}_1 \hat{\mathbf{x}} + \mathbf{h}_1)^T \\ \vdots \\ (\mathbf{G}_{q_1} \hat{\mathbf{x}} + \mathbf{h}_{q_1})^T \\ \mathbf{a}_1^T \\ \vdots \\ \mathbf{a}_{q_2}^T \end{bmatrix}, \quad (4.8)$$

čo môžeme dosiahnuť vhodnou voľbou matíc úlohy.

Sústava rovníc a nerovníc (4.2) - (4.7) ponúka pomerne jednoduchý spôsob na generovanie úloh (\mathcal{PNR}_C) v požadovanom tvare: Najprv zvolíme ľubovolné $\hat{\mathbf{x}}$ a $\hat{\mathbf{y}} \geq 0$, nato zvolíme matice a vektory $\mathbf{G}_i, \mathbf{h}_i, \mathbf{A}, i = 1, \dots, q$ (\mathbf{G}_i záporne definitné) tak, aby platilo (4.8). Následne zvolíme ľubovolné, kladne definitné matice \mathbf{D} a \mathbf{G} , a zo vzťahov (4.3) - (4.6) dopočítame vektory \mathbf{b}, \mathbf{t} . Na záver určíme \mathbf{h} z rovnice (4.2). Schematický popis implementácie tohto postupu je nasledovný:

Krok 1 : Inicializácia. Zvoľ n (počet premenných), m (počet ohraničení), $0 \leq q \leq m$ (počet kvadratických ohraničení), $m_a < n$ (počet aktívnych ohraničení v bode optima), ďalej nastav $\rho > 0$ (vzdialenosť bodu \mathbf{x}^0 od optimálneho riešenia) a $cond > 1$ (číslo podmienenosť matíc $\mathbf{D}, \mathbf{G}, \mathbf{G}_i$).

Krok 2 : Vygeneruj ľubovolné $\hat{\mathbf{x}} \in \mathbb{R}^n$ a ľubovolné také $\hat{\mathbf{y}} \geq 0$, ktoré obsahuje $m - m_a$ nulových prvkov a m_a kladných prvkov.

Krok 3 : Vytvor maticu $\mathbf{G} = \mathbf{Q}\Lambda\mathbf{Q}^T$, kde \mathbf{Q} je ľubovolná ortogonálna matica a Λ je diagonálna matica s prvkami $\lambda_i > 0$ zvolenými tak, aby platilo $\frac{\lambda_{\max}}{\lambda_{\min}} = cond$. Rovnako urči $\mathbf{G}_i = \mathbf{Q}_i \Lambda_i \mathbf{Q}_i^T$, pre Λ_i diagonálne s prvkami $\lambda_{ij} < 0$ zvolenými tak, aby platilo $\frac{\lambda_{i,\max}}{\lambda_{i,\min}} = cond$.

Krok 4 : Zvoľ $\mathbf{d} > 0$ tak, aby $\frac{d_{\max}}{d_{\min}} = cond$, a polož $\mathbf{D} = \text{diag}(\mathbf{d})$.

Krok 5 : Vygeneruj maticu \mathbf{A} a vektory $\mathbf{h}_i, i = 1, \dots, q$ tak, aby platilo (4.8), a dopočítaj vektory \mathbf{b}, \mathbf{t} podľa

$$\left. \begin{array}{ll} t_i = \frac{1}{2} \hat{\mathbf{x}}^T \mathbf{G}_i \hat{\mathbf{x}} + \mathbf{h}_i^T \hat{\mathbf{x}} - \theta_i & \text{ak } \mathbf{u}_i = 0 \\ t_i = \frac{1}{2} \hat{\mathbf{x}}^T \mathbf{G}_i \hat{\mathbf{x}} + \mathbf{h}_i^T \hat{\mathbf{x}} & \text{ak } \mathbf{u}_i > 0 \\ b_i = \mathbf{a}^T \hat{\mathbf{x}} - \theta_i & \text{ak } \mathbf{u}_{q+i} = 0 \\ b_i = \mathbf{a}^T \hat{\mathbf{x}} & \text{ak } \mathbf{u}_{q+i} > 0 \end{array} \right\} \begin{array}{l} i = 1, \dots, q, \\ i = 1, \dots, m - q, \end{array}$$

pričom $\theta_i > 0$ sú náhodné čísla.

Krok 6 : Z (4.2) dopočítaj \mathbf{h} .

Krok 7 : Zvoľ náhodne vektor \mathbf{s} a polož $\mathbf{x}^0 = \hat{\mathbf{x}} + \rho \frac{\mathbf{s}}{\|\mathbf{s}\|}$.

Krok 8 : Výstup : Matice a vektory dát $\hat{\mathbf{x}}, \hat{\mathbf{u}}, \mathbf{D}, \mathbf{G}, \mathbf{h}, \mathbf{G}_i, \mathbf{h}_i, \mathbf{t}, \mathbf{A}, \mathbf{b}, \mathbf{x}^0$.

Parametrami generátora sú konštanty $\{n, m, m_a, q, \rho, cond\}$, ktorých rozličným nastavením budú vznikať úlohy s rôznymi charakteristikami. Toto využijeme pri vykonávaní numerických experimentov.

Všimnime si ešte, že algoritmus nášho generátora úloh zabezpečí platnosť podmienky ostrej komplementarity (1.23). Maticu \mathbf{D} pri generovaní volíme diagonálnu.

4.2 Implementácie algoritmov

Na tomto mieste sa budeme venovať popisu algoritmov, ktoré použijeme na numerické experimentovanie. Konkrétnie sa bude jednať o:

- (a) Klasický algoritmus Rockafellara, kde použijeme dva rôzne prístupy pre odhad multiplikátorov: odhad prvého rádu a odhad druhého rádu.
- (b) Algoritmus nelineárneho škálovania pre vybranú transformačnú funkciu $\psi \in \mathcal{P}_{\text{NEQ}}^2$.
- (c) Algoritmus PDNRD Polyaka a Grivu.
- (d) „Fischerov“ algoritmus v dvoch verziách, ktoré nazveme „klasická“ a „modifikovaná“.

Detailey Newtonovho algoritmu na voľnú minimalizáciu a algoritmov na vyhľadávanie na lúči možno nájsť v Prílohe. Predtým, ako pristúpime ku konkrétnym implementáciám algoritmov, zadefinujme funkciu

$$\nu(\mathbf{x}, \mathbf{y}) = \max \left\{ \|\nabla_{\mathbf{x}} L(\mathbf{x}, \mathbf{y})\|, -\min_{1 \leq i \leq m} \{g_i(\mathbf{x})\}, \sum_{i=1}^m |\mathbf{y}_i g_i(\mathbf{x})|, -\min_{1 \leq i \leq m} \{\mathbf{y}_i\} \right\}, \quad (4.9)$$

ktorú nazveme „merit“ funkciou a budeme ňou merať kvalitu approximácie jednotlivých iteráčnych bodov $(\mathbf{x}^k, \mathbf{y}^k)$, keďže pre všetky uvažované algoritmy platí $\hat{\mathbf{u}} = \hat{\mathbf{y}}$. Predpokladáme, že vstup je vhodne škálovaný.

Na záver prezradíme, že všetky algoritmy sme naprogramovali v prostredí MATLAB (verzia 7.12). Kvôli snahe o zrýchlenie niektorých výpočtov kombinujeme klasické .m súbory so skompilovanými časťami kódu jazyku C v podobe .mex súborov, v ktorých využívame FORTRANovské funkcie z knižnice BLAS. Keďže sme chceli použiť na testovanie aj spomínaný testovací balík CUTER, museli sme pracovať pod operačným systémom LINUX (distribúcia Ubuntu, v11.04). Implementácia, ktorá je špeciálne určená pre výstup generátora úloh je však po vhodnom prekomplilovaní spustiteľná aj pod operačným systémom Windows.

4.2.1 Rockafellarov algoritmus

Pripomeňme označenia Rockafellarovej rozšírenej Lagrangeovej funkcie

$$\mathcal{L}_R(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) + \sum_{i=1}^m P_R(g_i(\mathbf{x}), \mathbf{y}_i),$$

s Rockafellarovou penalizačnou funkciou

$$P_R(\xi, \eta) = \begin{cases} \frac{1}{2}\xi^2 - \xi\eta & \text{pre } \xi < \eta \\ -\frac{\eta^2}{2} & \text{pre } \xi \geq \eta \end{cases}.$$

Algoritmus Rockafellara, ktorý sme teoreticky popísali v časti 2.2, sme implementovali nasledovne:

Krok 1 : Inicializácia. Urči konštanty ε (terminačné kritérium), $r_{\max} < 10^6$, $r_{\text{stp}} \in [2, 10]$ (konštanty použité na zmenu parametra r), δ (očakávaný pokles porušenia prípustnosti), konštanty $0 < \nu_{\text{crit}} \leq 1$, $odhad = 1$ a $0 < L < 1$, a urči hodnotu $r^0 > 0$. Polož $\mathbf{y}^0 = (1, \dots, 1)^T$ a $k = 0$.

Krok 2 : AK $\nu(\mathbf{x}^k, \mathbf{y}^k) < \varepsilon$, STOP, **Výstup** : $\mathbf{x}^k, \mathbf{y}^k$.

Krok 3 : Polož $\tilde{\mathbf{y}} = \text{multiplier}(\mathbf{x}^k, \mathbf{y}^k, odhad)$, označ $\mathbf{g}^k = \|\nabla_x \mathcal{L}_R(\mathbf{x}^k, \mathbf{y}^k)\|$ a použi Newtonovu metódu na približnú minimalizáciu funkcie $\mathcal{L}_R(\cdot, \mathbf{y}^k)$ na \mathbb{R}^n , bod minima označ \mathbf{x}^{k+1} . V tomto bode musí platiť

$$\|\nabla_x \mathcal{L}_R(\mathbf{x}^{k+1}, \mathbf{y}^k)\| < \frac{L}{r^k} \|\tilde{\mathbf{y}} - \mathbf{y}^k\| + \max\{1, \sqrt{r^k} \|\mathbf{g}^k\|\} \varepsilon.$$

Krok 4 : Polož $\mathbf{y}^{k+1} = \text{multiplier}(\mathbf{x}^{k+1}, \mathbf{y}^k, odhad)$.

Krok 5 : Označ $\delta_k = \frac{\max_i\{-g_i(\mathbf{x}^{k+1})\}}{\max_i\{-g_i(\mathbf{x}^k)\}}$, AK $\delta_k > \delta$, POTOM $r^{k+1} = \min\{r_{\text{stp}} r^k, r \frac{\delta_k}{\delta}, r_{\max}\}$, INAK $r^{k+1} = r^k$.

Krok 6 : AK $\nu(\mathbf{x}^{k+1}, \mathbf{y}^{k+1}) < \nu_{\text{crit}}$, POTOM $odhad = 2$.

Krok 7 : $k = k + 1$, CHOĎ NA KROK 2.

Pomocná funkcia $\text{multiplier}(\mathbf{x}, \mathbf{y}, odhad)$:

Krok 1 : AK $odhad = 1$, potom $\tilde{\mathbf{y}}_i = \max[0, \mathbf{y}_i - rg_i(\mathbf{x})], i = 1, \dots, m$.

AK $odhad = 2$, potom

$$\begin{aligned} \tilde{\mathbf{y}} = \mathbf{y} - \left[\nabla_{yy} d_R(\mathbf{y}) \right]^{-1} \times \\ \left[\nabla_y d_R(\mathbf{y}) - \nabla g(\mathbf{x}) \left[\nabla_{xx}^2 \mathcal{L}_R(\mathbf{x}, \mathbf{y}) \right]^{-1} \nabla_x \mathcal{L}_R(\mathbf{x}, \mathbf{y}) \right], \end{aligned}$$

a $\tilde{\mathbf{y}}_i = \max[0, \tilde{\mathbf{y}}_i], i = 1, \dots, m$, pričom význam a hodnoty symbolov $\nabla_y d_R(\mathbf{y})$ a $\nabla_{yy} d_R(\mathbf{y})$ nájdeme definované v časti 2.2.1.

Krok 2 : **Výstup** : $\tilde{\mathbf{y}}$.

Krátky komentár k uvedenej implementácii: Najväčšia výpočtová náročnosť algoritmu sa sústredí v kroku 3, v ktorom minimalizujeme Rockafellarovu rozšírenú Lagrangeovu funkciu, pričom terminačné kritérium je inšpirované vetou 2.2. Parameter ν_{crit} určuje, ktorú metódu odhadu multiplikátorov použijeme. Ak sa nachádzame

„ďaleko“ od optimálneho riešenia ($\nu(\mathbf{x}^k, \mathbf{y}^k)$ je veľké), použijeme odhad prvého rádu, pre malé hodnoty merit funkcie použijeme odhad druhého rádu. Parameter ν_{crit} teda určuje, kedy považujeme vzdialenosť za malú a kedy za veľkú. Pri experimentoch budeme používať dva varianty: v prvom zvolíme $\nu_{\text{crit}} = 0$ (vždy použijeme odhad prvého rádu), v druhom $\nu_{\text{crit}} = 1$ (použijeme oba odhady).

Parameter r meníme, ak algoritmus vykazuje veľmi pomalé znižovanie neprípustnosti bodov $(\mathbf{x}^k, \mathbf{y}^k)$. Ak pomer hodnôt neprípustnosti dvoch po sebe idúcich iterácií je väčší ako očakávaná hodnota δ , zmeníme r podľa vzťahu v kroku 5, inak ponecháme r bezo zmeny (pre detaily pozri [8]).

V experimentoch používame $r_{\max} = 5 \cdot 10^5$, $r_{\text{stp}} = 6$, $\delta = 0.5$, $L = 0.9$, $r^0 = 10$.

4.2.2 Nelineárne škálovanie

Implementácia tohto algoritmu je veľmi podobná ako implementácia Rockafellarovho algoritmu. Pripomeňme, že uvažujeme

$$\mathcal{L}_{\text{NR}}(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) + \frac{1}{r} \sum_{i=1}^m \mathbf{y}_i \psi(r g_i(\mathbf{x})), \quad (4.10)$$

kde sme zvolili

$$\psi(\xi) = \begin{cases} \xi^2 - \xi & \text{pre } \xi \leq 0, \\ \frac{1}{1+\xi} - 1 & \text{pre } \xi > 0. \end{cases} \quad (4.11)$$

Schematická implementáciu algoritmu:

Krok 1 : Inicializácia. Určí konštanty ε (terminačné kritérium), $r_{\max} < 10^6$, $r_{\text{stp}} \in [2, 10]$ (konstanty použité na zmenu parametra r), δ (očakávaný pokles porušenia prípustnosti), $0 < L < 1$, a určí hodnotu $r^0 > 0$. Polož $\mathbf{y}^0 = (1, \dots, 1)^T$ a $k = 0$.

Krok 2 : AK $\nu(\mathbf{x}^k, \mathbf{y}^k) < \varepsilon$, STOP, **Výstup** : $\mathbf{x}^k, \mathbf{y}^k$.

Krok 3 : Polož $\tilde{\mathbf{y}} = -\Psi'(rg(\mathbf{x}^k))\mathbf{y}^k$, označ $\mathbf{g}^k = \|\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^k, \mathbf{y}^k)\|$ a použi Newtonovu metódu na približnú minimalizáciu funkcie $\mathcal{L}_{\text{NR}}(\cdot, \mathbf{y}^k)$ na \mathbb{R}^n , bod minima označ \mathbf{x}^{k+1} . V tomto bode musí platiť

$$\|\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^{k+1}, \mathbf{y}^k)\| < \frac{L}{r^k} \|\tilde{\mathbf{y}} - \mathbf{y}^k\| + \max\{1, \sqrt{r^k}\} \|\mathbf{g}^k\| \varepsilon.$$

Krok 4 : Polož $\mathbf{y}^{k+1} = -\Psi'(rg(\mathbf{x}^{k+1}))\mathbf{y}^k$.

Krok 5 : Označ $\delta_k = \frac{\max_i\{-g_i(\mathbf{x}^{k+1})\}}{\max_i\{-g_i(\mathbf{x}^k)\}}$, AK $\delta_k > \delta$, POTOM $r^{k+1} = \min\{r_{\text{stp}} r^k, r \frac{\delta_k}{\delta}, r_{\max}\}$, INAK $r^{k+1} = r^k$.

Krok 6 : $k = k + 1$, CHOĎ NA KROK 2.

Vidíme, že schematický algoritmus je takmer totožný ako Rockafellarov algoritmus. Uvažujeme iba odhad multiplikátorov prvého rádu. Rovnako ako v prípade Rockafellarovho algoritmu používame $r_{\max} = 5 \cdot 10^5$, $r_{\text{stp}} = 6$, $\delta = 0.5$, $L = 0.9$, $r^0 = 10$.

4.2.3 Algoritmus PDNRD Polyaka a Grivu

Schematický popis uvedeného algoritmu Polyaka a Grivu sa bude od predošlých prípadov mierne odlišovať. V algoritme využijeme funkcie definované vzťahmi (4.10) a (4.11):

Krok 1 : Inicializácia. Určí konštanty ε (terminačné kritérium), $r_{\max} < 10^6$, $r_{\text{stp}} \in [2, 10]$ (konštanty použité na zmenu parametra r), δ (očakávaný pokles porušenia prípustnosti), $0 < L < 1$, $0 < \theta \leq 0.5$, a určí hodnotu $r^0 > 0$. Polož $\mathbf{y}^0 = (1, \dots, 1)^T$ a $k = 0$.

Krok 2 : AK $\nu(\mathbf{x}^k, \mathbf{y}^k) < \varepsilon$, STOP, **Výstup** : $\mathbf{x}^k, \mathbf{y}^k$.

Krok 3 : Nájdi $\Delta \mathbf{x}, \Delta \mathbf{y}$ zo sústavy

$$\begin{bmatrix} \nabla_{xx}^2 \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) & -\nabla g(\mathbf{x}^k)^T \\ r\Psi''(rg(\mathbf{x}^k)) \mathbf{Y} \nabla g(\mathbf{x}^k) & \mathbf{I}_m \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) \\ \tilde{\mathbf{y}} - \mathbf{y}^k \end{bmatrix}, \quad (4.12)$$

kde $\mathbf{Y} = \text{diag}(\mathbf{y}^k)$ a $\tilde{\mathbf{y}} = -\Psi'(rg(\mathbf{x}^k))\mathbf{y}^k$. Polož $\mathbf{x}_T^{k+1} = \mathbf{x}^k + \Delta \mathbf{x}$, $\mathbf{y}_T^{k+1} = \mathbf{y}^k + \Delta \mathbf{y}$.

Krok 4 : AK $\nu(\mathbf{x}_T^{k+1}, \mathbf{y}_T^{k+1}) < \min\{1 - \theta, \nu(\mathbf{x}^k, \mathbf{y}^k)^{1.5-\theta}\}$, POTOM polož $\mathbf{x}^{k+1} = \mathbf{x}_T^{k+1}$, $\mathbf{y}^{k+1} = \mathbf{y}_T^{k+1}$ a $r^{k+1} = \nu(\mathbf{x}^{k+1}, \mathbf{y}^{k+1})^{-1}$, $k = k + 1$, CHOĎ NA KROK 2.

Krok 5 : Polož $\tilde{\mathbf{y}} = -\Psi'(rg(\mathbf{x}^k))\mathbf{y}^k$, označ $\mathbf{g}^k = \|\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^k, \mathbf{y}^k)\|$ a použi Newtonovu metódu na približnú minimalizáciu funkcie $\mathcal{L}_{\text{NR}}(\cdot, \mathbf{y}^k)$ na \mathbb{R}^n , bod minima označ \mathbf{x}^{k+1} . V tomto bode musí platiť

$$\|\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^{k+1}, \mathbf{y}^k)\| < \frac{L}{r^k} \|\tilde{\mathbf{y}} - \mathbf{y}^k\| + \max\{1, \sqrt{r^k} \|\mathbf{g}^k\|\} \varepsilon.$$

Krok 6 : Polož $\mathbf{y}^{k+1} = -\Psi'(rg(\mathbf{x}^{k+1}))\mathbf{y}^k$.

Krok 7 : Označ $\delta_k = \frac{\max_i \{-g_i(\mathbf{x}^{k+1})\}}{\max_i \{-g_i(\mathbf{x}^k)\}}$, AK $\delta_k > \delta$, POTOM $r^{k+1} = \min\{r_{\text{stp}} r^k, r \frac{\delta_k}{\delta}, r_{\max}\}$, INAK $r^{k+1} = r^k$.

Krok 8 : $k = k + 1$, CHOĎ NA KROK 2.

Algoritmus je vlastne kombináciou primárno-duálneho algoritmu a nelineárneho škálovania. V každej iterácii sa pokúsime najprv spustiť primárno-duálnu metódou. Ak nový iteračný bod generovaný touto metódou dostatočne nezníži hodnotu merit funkcie (krok 4), znamená to, že sa ešte nachádzame príliš ďaleko od primárno-duálneho riešenia. Na získanie nového bodu $(\mathbf{x}^{k+1}, \mathbf{y}^{k+1})$ potom použijeme klasickú nelineárne škálovaciu metódu tak, ako sme popísali v závere časti 3.2. Môžeme si všimnúť, že zo sústavy (4.12) vynechávame regularizačný člen (porovnaj s (3.18)). Dôvod je ten, že

všetky úlohy generované algoritmom z časti 4.1 spĺňajú $\nabla_{xx}^2 \mathcal{L}(\mathbf{x}, \mathbf{y}) > 0$ pre ľubovoľné \mathbf{x} a $\mathbf{y} \geq 0$.

Parametre algoritmu v experimentoch volíme $r_{\max} = 5 \cdot 10^5$, $r_{\text{stp}} = 6$, $\delta = 0.5$, $L = 0.9$, $r^0 = 10$, $\theta = 0.35$.

4.2.4 Fischerove algoritmy

Algoritmy uvedené v časti 3.4 sú založené na použití Fischerovej funkcie na transformáciu KKT sústavy. Prvý algoritmus, „klasický“, bude založený výlučne na riešení tohto transformovaného systému.

Krok 1 : Inicializácia. Určí konštanty ε (terminačné kritérium), $0 < \mu$ (korekcia Fischerovej funkcie). Polož $\mathbf{y}^0 = (1, \dots, 1)^T$ a $k = 0$.

Krok 2 : AK $\nu(\mathbf{x}^k, \mathbf{y}^k) < \varepsilon$, STOP, **Výstup** : $\mathbf{x}^k, \mathbf{y}^k$.

Krok 3 : Nájdi $\Delta \mathbf{x}, \Delta \mathbf{y}$ zo sústavy

$$\begin{bmatrix} \nabla_{xx}^2 \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) & -\nabla g(\mathbf{x}^k)^T \\ \mathbf{D}_\alpha \nabla g(\mathbf{x}^k) & \mathbf{D}_\beta \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) \\ -\Phi_{F\mu}(g(\mathbf{x}^k), \mathbf{y}^k) \end{bmatrix}, \quad (4.13)$$

kde presné definície diagonálnych matíc a funkcie $\Phi_{F\mu}$ nájdeme v časti 3.4.

Krok 4 : Nájdi približné riešenie λ^k úlohy

$$\lambda^k = \arg \min_{\lambda > 0} \left\{ \|F(\mathbf{w}^k + \lambda \mathbf{s}^k)\| \right\}, \quad F(\mathbf{w}) = \begin{bmatrix} \nabla_x \mathcal{L}(\mathbf{x}, \mathbf{y}) \\ \Phi_{F\mu}(g(\mathbf{x}), \mathbf{y}) \end{bmatrix},$$

kde $\mathbf{w}^k = (\mathbf{x}^k, \mathbf{y}^k)$ a $\mathbf{s}^k = (\Delta \mathbf{x}, \Delta \mathbf{y})$.

Krok 5 : Polož $\mathbf{x}^{k+1} = \mathbf{x}^k + \lambda^k \Delta \mathbf{x}$, $\mathbf{y}_i^{k+1} = \max[0, \mathbf{y}_i^k + \lambda^k (\Delta \mathbf{y})_i]$, $i = 1, \dots, m$.

Krok 6 : $k = k + 1$, CHOĎ NA KROK 2.

Algoritmus je vlastne implementáciou Newtonovej metódy na riešenie sústavy rovníc (3.37), (3.38). Zároveň „ciele“ udržiavame body \mathbf{y}^k nezáporné a takisto upúštame od regularizácie sústavy (4.13) (rovnaké dôvody ako pri algoritme PDNRD v predchádzajúcej časti). V experimentoch volíme $\mu = m_\varepsilon = 2^{-52}$.

Druhá implementácia Fischerovho algoritmu bude založená na kombinácii predošlého algoritmu a nelineárne škálovacieho algoritmu.

Krok 1 : Inicializácia. Určí konštanty ε (terminačné kritérium), $r_{\max} < 10^6$, $r_{\text{stp}} \in [2, 10]$ (konštanty použité na zmenu parametra r), δ (očakávaný pokles porušenia prípustnosti), $0 < L < 1$, $0 < \mu$ (korekcia Fischerovej funkcie), $0 < \nu_{\text{crit}} \leq 1$, $alg = 2$ a urči r^0 .
Polož $\mathbf{y}^0 = (1, \dots, 1)^T$ a $k = 0$.

Krok 2 : AK $\nu(\mathbf{x}^k, \mathbf{y}^k) < \varepsilon$, STOP, **Výstup** : $\mathbf{x}^k, \mathbf{y}^k$.

Krok 3 : AK $alg = 1$, POTOM CHOĎ NA KROK 3, INAK CHOĎ NA KROK 6.

Krok 4 : Nájdi $\Delta \mathbf{x}, \Delta \mathbf{y}$ zo sústavy

$$\begin{bmatrix} \nabla_{xx}^2 \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) & -\nabla g(\mathbf{x}^k)^T \\ \mathbf{D}_\alpha \nabla g(\mathbf{x}^k) & \mathbf{D}_\beta \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = \begin{bmatrix} -\nabla_x \mathcal{L}(\mathbf{x}^k, \mathbf{y}^k) \\ -\Phi_{F\mu}(g(\mathbf{x}^k), \mathbf{y}^k) \end{bmatrix}, \quad (4.14)$$

kde presné definície diagonálnych matíc a funkcie $\Phi_{F\mu}$ nájdeme v časti 3.4.

Krok 5 : Polož $\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta \mathbf{x}$, $\mathbf{y}_i^{k+1} = \max[0, \mathbf{y}_i^k + (\Delta \mathbf{y})_i]$, $i = 1, \dots, m$, $k = k + 1$, CHOĎ NA KROK 2.

Krok 6 : Polož $\tilde{\mathbf{y}} = -\Psi'(rg(\mathbf{x}^k))\mathbf{y}^k$, označ $\mathbf{g}^k = \|\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^k, \mathbf{y}^k)\|$ a použi Newtonovu metódu na približnú minimalizáciu funkcie $\mathcal{L}_{\text{NR}}(\cdot, \mathbf{y}^k)$ na \mathbb{R}^n , bod minima označ \mathbf{x}^{k+1} . V tomto bode musí platiť

$$\|\nabla_x \mathcal{L}_{\text{NR}}(\mathbf{x}^{k+1}, \mathbf{y}^k)\| < \frac{L}{r^k} \|\tilde{\mathbf{y}} - \mathbf{y}^k\| + \max\{1, \sqrt{r^k}\|\mathbf{g}^k\|\}\varepsilon.$$

Krok 7 : Polož $\mathbf{y}^{k+1} = -\Psi'(rg(\mathbf{x}^{k+1}))\mathbf{y}^k$.

Krok 8 : Označ $\delta_k = \frac{\max_i\{-g_i(\mathbf{x}^{k+1})\}}{\max_i\{-g_i(\mathbf{x}^k)\}}$, AK $\delta_k > \delta$, POTOM $r^{k+1} = \min\{r_{\text{stp}} r^k, r \frac{\delta_k}{\delta}, r_{\text{max}}\}$, INAK $r^{k+1} = r^k$.

Krok 9 : AK $\nu(\mathbf{x}^{k+1}, \mathbf{y}^{k+1}) < \nu_{\text{crit}}$, POTOM polož $alg = 1$.

Krok 10 : $k = k + 1$, CHOĎ NA KROK 2.

Tento postup je vlastne heuristickým spojením dvoch odlišných algoritmov. V prvých iteráciach budeme najprv vykonávať klasický algoritmus nelineárneho škálovania, pokým nedostaneme dvojicu $\mathbf{x}^k, \mathbf{y}^k$, ktorej merit funkcia má menšiu hodnotu ako ν_{crit} . Potom prepnone na Fischerov algoritmus (v testoch volíme $\nu_{\text{crit}} = 0.1$, všetky ostatné konštanty volíme rovnako ako v pôvodných algoritmoch).

Ostatné parametre už tradične volíme $r_{\text{max}} = 5 \cdot 10^5$, $r_{\text{stp}} = 6$, $\delta = 0.5$, $L = 0.9$, $\mu = 2^{-52}$, $r^0 = 10$.

4.3 Výsledky experimentov

Po stručnom popísaní implementácie jednotlivých algoritmov môžeme pristúpiť k vykonaniu jednotlivých numerických experimentov. Budeme si všímať najmä vplyv zmeny veľkosti úlohy (vyjadrenú počtom premenných n a počtom ohraničení m), počtu aktívnych ohraničení k ich celkovému počtu (t.j. bude nás zaujímať pomery $\frac{m_a}{m}$), pomery kvadratických ohraničení (t.j. $\frac{q}{m}$) a nakoniec vplyv zmeny čísla podmienenosti matíc (determinujúcich funkcie (4.1)) na kvalitu dosiahnutých riešení. Kvalitu budeme posudzovať týmito kritériami:

- (a) Absolútne odchýlky polohy dosiahnutých aproximácií $\bar{\mathbf{x}}, \bar{\mathbf{y}}$ od známych optimálnych riešení $\hat{\mathbf{x}}, \hat{\mathbf{y}}$, t.j. budú nás zaujímať vzdialenosťi $\|\bar{\mathbf{x}} - \hat{\mathbf{x}}\|$ a $\|\bar{\mathbf{y}} - \hat{\mathbf{y}}\|$.
- (b) Výsledná norma gradientu klasickej Lagrangeovej funkcie $\|\nabla_{\mathbf{x}} L(\bar{\mathbf{x}}, \bar{\mathbf{y}})\|$ (označíme GRAD).
- (c) Porušenie komplementarity, vyjadrené pomocou $\sum_{i=1}^m |\bar{y}_i g_i(\bar{\mathbf{x}})|$ (KOMP).
- (d) Porušenie prípustnosti, t.j. $\max \left\{ \max_i \{-g_i(\bar{\mathbf{x}})\}, \max_i \{-\bar{y}_i\} \right\}$ (PRIP).
- (e) Časová náročnosť v sekundách.
- (f) Počet vykonaných makroiterácií (hodnota konštanty k vo všetkých algoritnoch).
- (g) Počet vykonaných mikroiterácií (počet iterácií vykonaných Newtonovou minimalizačnou metódou plus počet riešení špeciálnych sústav (4.12), (4.13) a (4.14)).

V každom experimente vykonáme pozorovania na sérii 10 náhodne generovaných úloh. Výsledky testov potom uvedieme v tabuľkách, v ktorých každý z riadkov bude obsahovať priemerné údaje z testovanej série. V tabuľkách budeme označovať implementované algoritmy skratkami:

AL_NR - Algoritmus rozšírenej Lagrangeovej funkcie používajúci funkcie nelineárneho škálovania.

AL_ROC1 - Algoritmus rozšírenej Lagrangeovej funkcie používajúci Rockafellarovu funkciu a odhad multiplikátorov prvého rádu.

AL_ROC1 - Algoritmus rozšírenej Lagrangeovej funkcie používajúci Rockafellarovu funkciu a kombinovaný odhad multiplikátorov (prvého aj druhého rádu).

FIS1 - Klasická verzia Fischerovho algoritmu.

FIS2 - Modifikovaná verzia Fischerovho algoritmu.

POL - Polyakov a Grivov algoritmus PDNRD.

Algoritmy sme testovali na počítači s procesorom Pentium(R) Dual-Core 2.10 GHz a s 3Gb operačnej pamäte typu DDR3, používajúci operačný systém Linux (distribúcia Ubuntu, v11.04).

Predtým, ako pristúpime k vykonaniu spomínaných experimentov, demonštrujeme funkčnosť algorimov na príklade malých rozmerov.

4.3.1 Ilustračný príklad

Na ilustráciu sme vybrali príklad zo známej zbierky testovacích úloh Hocka a Schittkowského (pôvodné zadania je možné nájsť v [42]), konkrétnie príklad s označením HS65 (príklad malých rozmerov s $n = 3$ a $m = 7$). Jeho formulácia je nasledovná:

$$\begin{aligned} \text{minimalizovať } & (\mathbf{x}_1 - \mathbf{x}_2)^2 + \frac{(\mathbf{x}_1 + \mathbf{x}_2 - 10)^2}{9} + (\mathbf{x}_3 - 5)^2 \\ \text{za podmienok } & 48 - \mathbf{x}_1^2 - \mathbf{x}_2^2 - \mathbf{x}_3^2 \geq 0 \\ & -4.5 \leq \mathbf{x}_i \leq 4.5, \quad i = 1, 2 \\ & -5 \leq \mathbf{x}_3 \leq 5. \end{aligned} \tag{4.15}$$

Kedžže analytický výpočet presného riešenia je pomerne náročný (vyžaduje riešiť polynómy štvrtého stupňa), v nasledujúcej tabuľke namiesto odchyiek polôh riešenia (kritérium **(a)**) uvedieme funkčnú hodnotu vo výslednom bode (označíme $\bar{f} \equiv f(\bar{\mathbf{x}})$). Použili sme terminačné kritérium $\varepsilon = 10^{-9}$, startovací bod je určený ako $\mathbf{x}^0 = (-5, 5, 0)^T$.

HOCK & SCHITTKOWSKI, p. 65							
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť
AL_NR	9.535E-01	2.254E-11	1.330E-12	8.043E-270	4	11	0.052
AL_ROC1	9.535E-01	3.178E-11	3.502E-15	2.737E-231	4	11	0.049
AL_ROC2	9.535E-01	8.882E-16	8.756E-16	8.043E-270	3	10	0.048
FIS1	9.535E-01	3.528E-11	2.032E-14	2.309E-13	8	8	0.076
FIS2	9.535E-01	2.554E-15	2.382E-14	2.736E-13	7	11	0.037
POL	9.535E-01	3.748E-11	9.862E-31	8.043E-270	4	16	0.070

Tabuľka 4.1: Riešenie ilustračného príkladu

Vidíme, že všetky použité algoritmy konvergujú veľmi rýchlo k optimálnemu riešeniu úlohy. Metóda Rockafellara dosahuje presnejšie výsledky pri použití odhadu druhého rádu, čo sme intuitívne očakávali. Veľmi dobre sa ukazujú aj Fischerove metódy a takisto PDNRD algoritmus Polyaka a Grivu.

4.3.2 Test č. 1: Vplyv rozmerov úlohy

Prvý test, ktorý vykonáme, sa zameriava na súvis zmeny veľkosti úlohy (počet premenných n a počet ohraničení m) so zmenou výkonu algoritmov. Budeme si všímať najmä zmenu počtu iterácií potrebných na konvergenciu a takisto na presnosť dosiahnutých riešení. Nastavenie parametrov generátora bude nasledovné: $n =$

$100, 200, 300$, $m = 2n$, $m_a = 0.25m$, $q = 0.25m$, $\rho = 5n$ a $cond = 10^2$, ako tolerančné kritérium zvolíme $\varepsilon = 10^{-6}$. V tabuľke sumerizujeme výsledky:

TEST č. 1, VÝSLEDKY									
ALG	$\ \bar{x} - \hat{x}\ $	$\ \bar{y} - \hat{y}\ $	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
$n = 100, m = 200, m_a = 50, m_q = 50, \rho = 500$									
AL_NR	1.451E-09	2.994E-06	2.034E-07	5.044E-07	3.633E-08	10.10	32.50	2.639	
AL_ROC1	5.000E-10	1.075E-06	5.438E-08	2.800E-07	4.298E-09	14.30	30.40	2.273	
AL_ROC2	3.061E-10	8.144E-07	1.589E-08	2.566E-07	5.169E-09	6.90	24.60	1.846	
FIS1	2.311E-12	4.546E-09	1.310E-10	5.028E-10	1.298E-10	19.80	19.80	3.754	
FIS2	1.084E-13	2.071E-10	1.164E-10	2.434E-11	7.105E-12	8.60	28.10	2.215	
POL	2.026E-11	3.752E-08	5.821E-11	1.441E-08	7.388E-10	9.20	30.20	2.122	
$n = 200, m = 400, m_a = 100, m_q = 100, \rho = 1000$									
AL_NR	1.236E-09	4.694E-06	1.180E-06	8.743E-07	5.553E-08	11.10	35.30	23.668	
AL_ROC1	1.404E-10	3.264E-07	4.036E-07	2.191E-07	2.166E-09	14.40	35.70	21.149	
AL_ROC2	2.462E-11	1.663E-11	1.198E-06	4.752E-07	6.705E-09	8.10	30.10	16.846	
FIS1	1.103E-12	2.824E-09	1.164E-10	4.970E-10	6.435E-11	21.90	21.90	31.987	
FIS2	1.510E-14	1.908E-11	3.492E-10	9.862E-11	3.638E-12	8.70	32.40	17.184	
POL	2.241E-11	5.145E-08	2.328E-10	1.305E-08	1.226E-09	9.20	33.00	16.991	
$n = 300, m = 600, m_a = 150, m_q = 150, \rho = 1500$									
AL_NR	5.005E-10	1.865E-06	2.426E-06	6.524E-07	2.846E-08	11.30	37.50	226.601	
AL_ROC1	1.021E-10	2.304E-07	5.632E-07	2.728E-07	1.826E-09	14.50	39.20	179.374	
AL_ROC2	4.320E-11	3.214E-11	1.502E-06	5.190E-07	4.158E-09	8.40	32.80	141.009	
FIS1	2.486E-09	1.543E-05	4.064E-07	8.822E-07	4.397E-07	23.30	23.30	253.049	
FIS2	1.181E-13	6.614E-10	3.492E-10	2.447E-10	1.762E-11	8.30	34.70	162.137	
POL	4.920E-11	1.577E-07	2.328E-10	7.108E-08	5.298E-09	9.10	33.80	154.684	

Tabuľka 4.2: Súhrnné výsledky pre test č. 1

Výsledky do veľkej miery potvrdzujú naše očakávania. Príjemným konštatovaním je fakt, že požadovaná presnosť bola dosiahnutá vo všetkých prípadoch, odchýlky presnosti polohy \bar{x} a \bar{y} sú takisto veľmi dobré. V tomto smere sa sľubne ukazujú metódy študované v Kapitole 3, čiže PDNRD algoritmus Polyaka a Grivu a obe modifikácie Fischerovho algoritmu. Všimnúť si môžeme aj vplyv použitia odhadu multiplikátorov druhého rádu na presnosť vektora multiplikátorov \bar{y} oproti použitiu odhadu prvého rádu v prípade Rockafellarovho algoritmu.

Zväčšujúci sa rozmer úlohy však viac alebo menej vplýva na počet vykonaných iterácií, ale najmä na časovú náročnosť. Počty hlavných iterácií sa zväčšujú len ne-patrne, sumárny počet Newtonovských iterácií stúpol najviac v prípade Rockafellarovho algoritmu (2nd order update), konkrétnie o 33%. Rapídny vzrast si všimneme

v prípade časovej náročnosti. Tento je spôsobený jednak zmenou rozmerov úlohy, a takisto zväčšujúcim sa počtom kvadratických ohraničení, ktoré je nutné vyčíslovať v každej iterácii.

4.3.3 Test č. 2: Zmena počtu ohraničení

V tomto teste sa zameriame výlučne na zmenu počtu ohraničení, kým počet premenných ponecháme konštantný. Budeme uvažovať $n = 100$ a postupne budeme voliť $m = 100, 300, 500$. Ku každej kombinácii potom priradíme ostatné parametre generátora predpisom $q = 0.25m, m_a = 0.6n, \rho = 5n$ a $cond = 10^2$. Podobne ako v predošлом teste zvolíme $\varepsilon = 10^{-6}$.

TEST č. 2, VÝSLEDKY									
ALG	$\ \bar{x} - \hat{x}\ $	$\ \bar{y} - \hat{y}\ $	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
$n = 100, m = 100, m_a = 60, m_q = 25, \rho = 500$									
AL_NR	1.110E-09	3.323E-06	2.539E-07	3.649E-07	2.095E-08	11.40	32.50	1.485	
AL_ROC1	6.008E-10	1.567E-06	1.321E-07	3.673E-07	4.690E-09	14.20	30.40	1.246	
AL_ROC2	3.190E-10	5.275E-07	1.345E-06	2.254E-07	3.138E-09	7.80	24.20	1.015	
FIS1	1.717E-09	4.834E-06	1.328E-07	1.535E-07	7.430E-08	18.30	18.30	1.971	
FIS2	4.410E-12	1.081E-08	4.578E-09	1.970E-09	2.735E-10	7.70	25.90	1.104	
POL	2.492E-10	5.010E-07	1.110E-10	1.173E-07	8.925E-09	9.50	29.40	1.100	
$n = 100, m = 300, m_a = 60, m_q = 75, \rho = 1000$									
AL_NR	3.665E-08	2.948E-05	9.813E-06	4.209E-07	2.045E-08	11.30	34.70	4.175	
AL_ROC1	7.116E-10	2.058E-06	9.482E-08	5.649E-07	7.176E-09	13.80	32.80	3.596	
AL_ROC2	7.545E-11	1.490E-07	4.058E-07	9.406E-08	1.564E-09	8.50	27.60	3.141	
FIS1	4.559E-09	5.459E-06	8.165E-06	1.883E-07	9.350E-08	21.30	21.30	6.424	
FIS2	1.236E-11	2.643E-08	6.275E-08	1.864E-08	9.334E-10	8.00	28.90	3.210	
POL	2.290E-09	5.618E-06	2.832E-10	3.725E-07	3.503E-08	9.00	31.40	3.193	
$n = 100, m = 500, m_a = 60, m_q = 125, \rho = 1000$									
AL_NR	2.967E-09	6.626E-06	3.704E-07	2.999E-07	1.271E-08	11.40	34.20	6.481	
AL_ROC1	7.771E-10	2.024E-06	7.080E-08	5.149E-07	8.199E-09	13.80	32.50	5.654	
AL_ROC2	9.382E-11	1.723E-07	3.505E-08	9.180E-08	1.188E-09	8.00	27.10	4.952	
FIS1	1.289E-09	2.125E-06	3.307E-06	2.125E-07	6.695E-08	22.90	22.90	11.915	
FIS2	4.189E-09	5.152E-06	6.274E-05	1.545E-07	6.452E-09	8.40	28.80	5.185	
POL	6.019E-10	1.284E-06	2.197E-10	2.053E-07	1.566E-08	9.70	31.30	5.081	

Tabuľka 4.3: Súhrnné výsledky pre test č. 2

Vidíme, že presnosť dosiahnutých riešení primárnej premennej \bar{x} aj duálnej premennej \bar{y} je v každom z nastavení parametrov takmer rovnaká. Zaujímavá je najmä

takmer rovnaká dosiahnutá presnosť pre \bar{y} , keďže práve počet multiplikátorov sa v rámci testu zvyšuje. Všetky algoritmy produkujú porovnatelne presné riešenia, hoci v niektorých prípadoch nedosahuje norma gradientu Lagrangeovuj funkcie požadovanú presnosť.

Časová náročnosť má podľa očakávania rastúcu tendenciu, keďže viac ohraničení znamená viac ich vyčíslení. Nárast však nie je taký markantný ako v prípade predchádzajúceho testu. Situácia ohľadom počtu vykonaných iterácií nie je jednoznačná: v niektorých prípadoch pozorujeme mierny nárast, v iných prípadoch stagnáciu či dokonca mierny pokles. Prevažujúci trend je však mierne rastúci.

V rámci tohto testu teda uspeli všetky porovnávané algoritmy, čo je uspokojivé.

4.3.4 Test č. 3: Zmena počtu aktívnych ohraničení

V doterajších testoch sme sa príliš nezameriavali na pomer počtu aktívnych ohraničení k ich celkovému počtu. V prvom teste bol tento pomer konštantný, v druhom sa vplyvom zmeny počtu ohraničení nepriamo menil. V tomto teste sa zameriame výlučne na skúmanie vplyvu daného pomeru na iteračnú a časovú náročnosť, a takisto na presnosť dosiahnutých riešení. Zvolíme $n = 100, m = 100, q = 50, \rho = 500, cond = 10^2$ a budeme uvažovať pomery $\frac{m_a}{m} = 0.1, 0.4, 0.7, 0.95$. Tradične budeme voliť $\varepsilon = 10^{-6}$.

Z výsledkov uvedených v tabuľke 4.4 opäť vidíme, že dosiahnutá presnosť či už primárnej premennej \bar{x} alebo duálnej premennej \bar{y} je vo všetkých skúmaných scenároch takmer rovnaká. Mierny pokles si môžeme všimnúť až pri nastavení $\frac{m_a}{m} = 0.95$.

Práve v tomto teste je najlepšie vidieť rast počtu iterácií, či už hlavných iterácií alebo sumárneho počtu Newtonovských iterácií. Pri zvyšovaní počtu aktívnych ohraničení sa stále viac ohraničení realizuje v optimálnom bode ako rovnosti, a tento fakt zrejme sťažuje konvergenciu algoritmov. Najlepšie je tento fakt vidieť pri prechode $\frac{m_a}{m} : 0.7 \rightarrow 0.95$. Pri tomto nastavení v niektorých prípadoch mierne klesá dosiahnutá presnosť vektora multiplikátorov a takisto normy gradientu Lagrangeovej funkcie. Priamym dôsledkom zvyšovania počtu iterácií je aj zvýšenie časovej náročnosti.

TEST č. 3, VÝSLEDKY									
ALG	$\ \bar{x} - \hat{x}\ $	$\ \bar{y} - \hat{y}\ $	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
$n = 100, m = 100, m_a = 10, q = 50, \rho = 1000$									
AL_NR	7.865E-08	1.354E-05	1.889E-06	5.512E-07	1.917E-08	10.40	30.10	2.467	
AL_ROC1	1.629E-09	6.107E-07	3.148E-09	4.634E-07	4.068E-08	11.50	27.90	2.096	
AL_ROC2	5.889E-10	1.462E-07	6.425E-07	1.408E-07	1.222E-08	6.00	22.50	1.760	
FIS1	1.518E-11	2.178E-09	7.233E-09	7.272E-09	1.441E-09	16.90	16.90	3.096	
FIS2	4.585E-13	5.916E-11	5.937E-10	4.540E-10	4.354E-11	5.80	24.60	1.836	
POL	8.523E-10	2.339E-07	5.251E-10	1.743E-07	2.600E-08	6.30	25.30	1.816	
$n = 100, m = 100, m_a = 40, q = 50, \rho = 1000$									
AL_NR	1.940E-09	3.252E-06	1.344E-07	4.551E-07	3.934E-08	10.40	31.90	2.548	
AL_ROC1	5.438E-10	8.460E-07	3.024E-08	4.007E-07	1.111E-08	13.10	29.90	2.137	
AL_ROC2	1.268E-10	1.880E-07	1.005E-08	1.186E-07	2.424E-09	7.70	24.70	1.807	
FIS1	1.961E-10	2.101E-07	1.779E-08	8.152E-08	8.718E-10	18.60	18.60	3.359	
FIS2	3.309E-12	1.830E-09	2.856E-08	1.733E-08	3.879E-10	7.20	26.60	1.958	
POL	2.433E-10	3.228E-07	1.135E-10	9.221E-08	1.142E-08	8.40	28.10	1.887	

Tabuľka 4.4: Súhrnné výsledky pre test č. 3

TEST č. 4, VÝSLEDKY									
ALG	$\ \bar{x} - \hat{x}\ $	$\ \bar{y} - \hat{y}\ $	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
$n = 100, m = 100, m_a = 70, q = 50, \rho = 1000$									
AL_NR	1.290E-09	4.342E-06	8.152E-07	3.547E-07	1.730E-08	11.10	34.10	2.678	
AL_ROC1	7.262E-10	2.410E-06	1.971E-07	4.204E-07	7.085E-09	14.10	33.00	2.311	
AL_ROC2	6.470E-10	8.283E-07	7.048E-06	4.872E-07	6.288E-09	7.60	26.20	1.893	
FIS1	6.411E-10	1.641E-06	3.309E-07	1.388E-07	2.225E-08	19.60	19.60	3.605	
FIS2	1.104E-09	2.286E-06	6.493E-05	2.931E-08	1.393E-09	8.00	28.50	2.066	
POL	2.418E-10	6.405E-07	1.019E-10	7.732E-08	7.827E-09	9.90	31.40	2.025	
$n = 100, m = 100, m_a = 95, q = 50, \rho = 1000$									
AL_NR	4.120E-09	7.758E-05	2.381E-05	4.426E-07	1.461E-08	13.60	39.70	3.099	
AL_ROC1	2.210E-09	4.007E-05	7.493E-06	3.723E-07	3.827E-09	15.60	36.70	2.499	
AL_ROC2	1.367E-09	8.513E-06	2.332E-05	2.993E-07	3.149E-09	9.00	28.60	2.031	
FIS1	1.466E-09	1.563E-05	4.061E-08	1.208E-07	1.723E-08	30.50	30.50	5.486	
FIS2	3.132E-10	2.665E-06	6.430E-07	6.247E-08	6.630E-09	8.60	29.10	2.102	
POL	2.836E-09	5.838E-05	2.119E-05	3.335E-07	1.352E-08	14.00	39.10	2.417	

Tabuľka 4.4: Súhrnné výsledky pre test č. 3, pokračovanie

4.3.5 Test č. 4: Zmena počtu kvadratických ohraničení

Teraz sa zameriame na sledovanie vplyvu pomeru kvadratických ohraničení k celkovému počtu ohraničení. Dá sa očakávať, že úloha s väčším podielom nelineárnych

funkcií bude ľažšie riešiteľná. Za týmto účelom zafixujeme $n = 100, m = 100, m_a = 40, \rho = 500, cond = 10^2$, postupne budeme voliť $q = 10, 30, 70, 95$ a uvidíme, či sa naše domienky potvrdia.

TEST č. 4, VÝSLEDKY									
ALG	$\ \bar{x} - \hat{x}\ $	$\ \bar{y} - \hat{y}\ $	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
$n = 100, m = 100, m_a = 50, q = 10, \rho = 1000$									
AL_NR	1.597E-09	3.247E-06	1.254E-07	4.973E-07	2.563E-08	10.90	29.10	0.749	
AL_ROC1	7.266E-10	1.444E-06	3.559E-08	5.284E-07	7.750E-09	13.50	28.30	0.698	
AL_ROC2	2.957E-10	9.136E-06	1.084E-06	3.831E-07	2.988E-08	7.40	22.40	0.536	
FIS1	6.925E-10	1.588E-06	4.069E-08	1.448E-07	3.371E-08	16.90	16.90	1.023	
FIS2	2.956E-12	6.128E-09	1.717E-10	2.725E-10	1.507E-10	7.40	23.00	0.552	
POL	7.880E-10	1.509E-06	1.019E-10	2.199E-07	3.608E-08	8.70	26.00	0.553	
$n = 100, m = 100, m_a = 50, q = 40, \rho = 1000$									
AL_NR	1.564E-09	3.054E-06	2.606E-07	4.911E-07	3.215E-08	10.30	32.20	2.145	
AL_ROC1	7.809E-10	1.282E-06	5.090E-08	5.295E-07	1.016E-08	13.20	30.30	1.786	
AL_ROC2	8.742E-11	1.130E-07	1.313E-08	7.994E-08	1.321E-09	7.90	25.50	1.604	
FIS1	5.972E-10	1.101E-06	6.025E-08	2.262E-07	4.484E-09	17.90	17.90	2.760	
FIS2	4.141E-11	5.472E-08	5.219E-08	2.394E-08	2.212E-09	7.30	26.30	1.607	
POL	2.334E-10	2.888E-07	1.048E-10	6.979E-08	6.905E-09	8.80	29.80	1.638	
$n = 100, m = 100, m_a = 50, q = 70, \rho = 1000$									
AL_NR	1.157E-09	2.453E-06	2.575E-07	3.424E-07	3.415E-08	10.40	32.10	3.532	
AL_ROC1	7.036E-10	1.446E-06	5.795E-08	5.515E-07	1.578E-08	13.00	30.40	3.196	
AL_ROC2	7.041E-11	1.152E-07	1.856E-08	6.677E-08	1.852E-09	7.90	25.30	2.569	
FIS1	1.896E-10	2.416E-07	2.196E-08	1.003E-07	2.734E-09	18.40	18.40	4.864	
FIS2	1.821E-11	2.565E-08	1.175E-07	5.222E-08	1.139E-09	7.00	26.70	2.742	
POL	6.808E-10	9.970E-07	1.426E-10	1.790E-07	2.840E-08	8.20	28.80	2.930	
$n = 100, m = 100, m_a = 50, q = 95, \rho = 1000$									
AL_NR	1.655E-09	1.376E-06	5.020E-08	3.736E-07	3.770E-08	10.00	32.20	4.577	
AL_ROC1	7.738E-10	1.096E-06	2.468E-08	4.672E-07	3.109E-08	12.10	29.70	3.821	
AL_ROC2	8.417E-11	1.111E-07	1.256E-08	1.046E-07	2.687E-09	6.50	24.20	3.359	
FIS1	8.125E-11	8.729E-08	6.015E-07	7.058E-08	3.353E-09	18.80	18.80	6.329	
FIS2	1.305E-13	1.909E-10	4.540E-10	4.197E-10	8.728E-12	5.90	26.20	3.520	
POL	5.942E-10	7.886E-07	3.347E-10	1.448E-07	2.981E-08	6.90	27.70	3.500	

Tabuľka 4.5: Súhrnné výsledky pre test č. 4

Výsledky testu sú viac ako zaujímavé. Ukazuje sa totiž, že okrem zvyšovania časovej náročnosti (čo sa očakávalo, keďže vyčíslenie kvadratických ohraničení je náročnejšie ako lineárnych) nedochádza k žiadnej výraznej zmene vo všetkých ostatných sledovaných veličinách. Pri použití metód využívajúcich informácie druhého rádu však v prípade kvadratických funkcií nedochádza k strate informácie. To je

jedno z možných vysvetlení výsledkov.

Dosiahnuté výsledky sú opäť veľmi presné, všetky algoritmy skonvergovali k dosťatočne presným aproximáxiám skutočných riešení, pričom počet iterácií zostal relatívne malý. Uvidíme, či sa situácia zmení, ak na testovanie použijeme úlohy, kde Hessove matice funkcií týchto úloh budú zle podmienené.

4.3.6 Test č. 5: Zmena čísla podmienenosťi

Na záver ešte vykonáme test na zle podmienených úlohách. Zafixujeme preto $n = 100, m = 200, m_a = 80, q = 50, \rho = 500$ a budeme voliť rôzne čísla podmienenosťi matíc vystupujúcich v definíciach funkcií (4.1), konkrétnie vyskúšame $cond = 10, 10^6, 10^{12}$. Výsledky sumarizuje nasledujúca tabuľka.

TEST č. 5, VÝSLEDKY									
ALG	$\ \bar{x} - \hat{x}\ $	$\ \bar{y} - \hat{y}\ $	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
$n = 100, m = 200, m_a = 80, q = 50, \rho = 1000, cond = 10$									
AL_NR	1.624E-09	3.347E-06	1.587E-06	4.086E-07	1.421E-08	11.30	40.30	3.210	
AL_ROC1	1.243E-09	2.846E-06	4.636E-07	5.089E-07	5.311E-09	14.20	39.30	2.844	
AL_ROC2	6.874E-10	1.035E-06	5.768E-07	4.903E-07	5.132E-09	7.60	31.60	2.394	
FIS1	3.263E-10	5.064E-07	2.467E-08	6.824E-08	5.679E-09	25.30	25.30	4.924	
FIS2	1.894E-12	3.896E-09	2.101E-10	3.111E-10	7.325E-11	8.50	34.80	2.567	
POL	4.273E-10	7.497E-07	7.331E-11	1.461E-07	7.603E-09	10.40	37.20	2.485	
$n = 100, m = 200, m_a = 80, q = 50, \rho = 1000, cond = 10^6$									
AL_NR	1.519E-09	7.074E-05	9.180E-05	4.364E-07	1.575E-08	12.90	33.70	2.544	
AL_ROC1	1.276E-09	5.674E-05	8.837E-07	5.920E-07	6.178E-09	15.10	29.60	2.057	
AL_ROC2	1.144E-10	1.204E-05	1.656E-03	1.934E-07	3.638E-09	8.90	23.20	1.666	
FIS1	5.426E-10	1.735E-05	4.734E-08	1.487E-07	1.833E-08	27.50	27.50	5.407	
FIS2	8.476E-12	1.415E-07	2.055E-06	1.226E-08	3.414E-10	9.50	25.80	1.764	
POL	6.868E-10	2.703E-05	7.451E-10	1.588E-07	7.110E-09	14.20	35.20	2.089	
$n = 100, m = 200, m_a = 80, q = 50, \rho = 1000, cond = 10^{12}$									
AL_NR	1.590E-09	3.039E-04	8.654E-04	3.712E-07	8.150E-09	13.00	32.20	2.428	
AL_ROC1	8.974E-10	1.685E-04	2.968E-06	4.074E-07	3.976E-09	15.70	30.70	2.090	
AL_ROC2	1.895E-11	3.217E-06	2.636E-04	2.681E-08	5.238E-10	8.60	21.30	1.517	
FIS1	4.147E-11	5.254E-06	2.500E-09	9.421E-09	1.084E-09	31.90	31.90	6.368	
FIS2	2.528E-12	4.415E-07	2.073E-08	1.777E-10	1.330E-10	10.00	24.90	1.650	
POL	1.252E-09	2.612E-04	6.925E-04	3.870E-07	8.808E-09	15.50	36.00	2.185	

Tabuľka 4.6: Súhrnné výsledky pre test č. 5

Výsledky sú opäť zaujímavé. Výrazné zvýšenie čísla podmienenosťi neviedlo v

niektorých prípadoch k takmer žiadnemu zhoršeniu výkonu algoritmov. Zhoršenie podmienosti matíc determinujúcich funkcie úlohy toriž nemusí automaticky znamenať zhoršenie podmienenosť Hessovej matice klasickej či rozšírenej Lagrangeovej funkcie.

Zaznamenali sme mierny pokles presnosti aproximáxií multiplikátorov \bar{y} (napr. AL_NR alebo POL), a takisto veľkosť normy gradientu Lagrangeovej funkcie v niektorých prípadoch nedosahuje požadovanú presnosť 10^{-6} . Súhranne v tomto teste celkom dobre dopadli Fisherove algoritmy.

4.3.7 Zbierka CUTEr

Na záver vykonáme testy na niekoľkých vybraných úlohách zo zbierky príkladov CUTEr [18]. Jedná sa o zborník obsahujúci príklady na voľnú aj viazanú optimalizáciu. Všeobecný tvar úloh obsiahnutých v tomto zborníku je

$$\begin{aligned} & \text{minimalizovať} \quad f(\mathbf{x}) \\ & \text{za podmienok} \quad \mathbf{b}_i \leq g_i(\mathbf{x}) \leq \mathbf{c}_i, \quad i = 1, \dots, m \\ & \quad h_i(\mathbf{x}) = \mathbf{d}_i, \quad i = 1, \dots, p \\ & \quad \boldsymbol{\alpha}_i \leq \mathbf{x}_i \leq \boldsymbol{\beta}_i, \quad i = 1, \dots, n. \end{aligned} \tag{4.16}$$

pre $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ($i = 1, \dots, m$) a $h_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ($i = 1, \dots, p$). Niektoré prvky vektorov $\mathbf{b}, \boldsymbol{\alpha}$ môže byť $-\infty$ a analogicky môže byť niektoré prvky $\mathbf{c}, \boldsymbol{\beta}$ rovné ∞ . Úlohy vykazujú rôzne stupne nelinearity, zbierka taksito obsahuje množstvo nekonvexných úloh.

Naše testovanie zameriame na niektoré vybrané úlohy konvexného programovania. Aby sme mohli lepšie využiť štruktúru úlohy 4.16, rozšírili sme algoritmy z časti (4.2) aj pre zvládnutie ohraničení v tvare rovností. Keďže toto rozšírenie je pomerne priamočiare, preto detaľy na tomto mieste uvádzat nebudeeme. Výsledky numerického experimentu sú uvedené v druhej časti Prílohy a zdrojové kódy portu algoritmov na testovanie CUTEr úloh sú obsiahnuté na priloženom médiu.

Väčšinu úloh dokázali vyriešiť všetky algoritmy. Klasický Fischerov algoritmus mal spomedzi testovaných algoritmov najväčšie problémy. Naopak najlepšie si viedli PDNRD algoritmus Polyaka a Grivu a modifikovaný Fischerov algoritmus.

Záver

V tejto práci sme sa venovali teoretickému popisu a implementácii algoritmov na riešenie úlohy konvexného programovania (\mathcal{PNR}_C) a ich experimentálnemu porovnaniu. Prevažnú časť algoritmov tvorili metódy rozšírených Lagrangeových funkcií, konkrétnie Rockafellarov algoritmus (časť 2.2) a všeobecný algoritmus nelineárneho škálovania (2.3.2 a 3.1). Spolu s uvedenými algoritmami sme študovali primárno-duálny nelineárne škálovací algoritmus (PDNRD, časti 3.2, 3.3) Polyaka a Grivu a dva varianty Fischerovho algoritmu (časť 3.4). Algoritmy sme implementovali pre prostredie MATLAB, pričom využívame `mex` funkcie (skompilovaný kód jazyka C) a procedúry knižnice BLAS v snahe urýchliť niektoré výpočty. Ukážky zdrojových kódov sú priložené v Prílohe.

Tieto algoritmy sme podrobili testovaniu na sériach náhodne generovaných úloh bkvadratického programovania a takisto na vybraných úlohách zo známeho testovacieho prostredia CUTEr.

Na testoch pozostávajúcich z náhodne generovaných úloh dosahovali všetky algoritmy podobné výsledky, dosiahnutá presnosť riešení bola postačujúca. Môžeme si však všimnúť zväčšenú presnosť a miernu iteračnú a časovú úsporu algoritmov PDNRD, modifikovaného Fischerovho algoritmu a Rockafellarovho algoritmu s použitím odhadu multiplikátorov druhého rádu v porovnaní s ostatnými metódami. Prístup kombinovania klasických algoritmov rozšírených Lagrangeových funkcií a riešenia špeciálnych sústav v záverečnej časti výpočtového procesu, ktoré PDNRD a modifikovaný Fischerov algoritmus využívajú, sa zdá byť užitočný. Takisto sa prejavuje vplyv odhadu multiplikátorov druhého rádu.

V testovaniach na príkladoch zo zborníka CUTEr si najlepšie viedli klasický algoritmus nelineárneho škálovania, PDNRD algoritmus a modifikovaný Fischerov algoritmus, ktoré vyriešili takmer všetky úlohy. Veľkú väčšinu úloh však vyriešili veľmi presne všetky testované algoritmy.

Niektoré dôležité otázky zostávajú zatiaľ nezodpovedané: porovnanie teoretickej rýchlosťi konvergencie PDNRD algoritmu s Fischerovým algoritmom a prípadná reformulácia týchto algoritmov na riešenie úloh nekonvexného programovania. V týchto oblastiach je priestor pre ďalší výskum.

Literatúra

- [1] Bertsekas D. P., *Constrained Optimization and Lagrange Multiplier Methods*, Athena Scientific, 1996
- [2] Bertsekas D. P., Nedić A., Ozdaglar A. E., *Convex Analysis and Optimization*, Athena Scientific, Massachusetts, 560 s., 2003
- [3] Bertsekas D. P., *Nonlinear Programming*, Athena Scientific, 2nd edition, 1999
- [4] Birgin E. G., Castillo R. A., Martínez J. M., *Numerical Comparison of Augmented Lagrangian Algorithms for Nonconvex Problems*, Computational Optimization and Applications, Vol. 31, No. 1, s. 31-55, 2005.
- [5] Boyd S., Vanderberghe L., *Convex Optimization*, Cambridge University Press, 730 s., 2004
- [6] Brent R. P., *Algorithms for Minimization Without Derivatives*, Prentice-Hall, Eaglewood Cliffs, N. J., 208 s., 1973
- [7] Byrd R. H., *Local Convergence of the Diagonalized Method of Multipliers*, Journal of Optimization Theory and Applications, Vol. 26, s. 485-500, 1978
- [8] Delbos F., Gilbert J. Ch., *Global Linear Convergence of an Augmented Lagrangian Algorithm to Solve Convex Quadratic Optimization Problems*, Journal of Convex Analysis, Volume 12, No. 1, s. 45-69, 2005
- [9] Dennis J. E., Schnabel R. B., *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*, Society for Industrial Mathematics, 394 s., 1987
- [10] Fletcher R., *Practical Methods Of Optimization*, 2nd Edition, John Wiley & Sons, 450 s., 1987

- [11] Facchinei F., Fischer A., Kanzow C., *A Semismooth Newton Method For Variational Inequalities, The Case of Box Constraints*, Complementarity and Variational Problems: State of the Art. SIAM, s. 76-90, 1997
- [12] Facchinei F., Fischer A., Kanzow C., Peng J., *A Simplicy Constrained Optimization Reformulation of KKT Systems Arising From Variational Inequalities*, Applied Mathematics & Optimization, Vol. 40, No. 1, s. 19-37, 1999
- [13] Facchinei F., Soares J., *Testing a New Class of Algorithms for Nonlinear Complementarity Problems*, DIS Technical Report 15.94, 1994
- [14] Fischer A., *A Special Newton-Type Optimization Method*, Optimization, Vol. 24, s. 269-284, 1992
- [15] Fischer A., *A Newton-type Method for Positive-Semidefinite Linear Complementarity Problems* Journal of Optimization Theory and Applications, Vol. 86, No. 3, s. 585-608, 1995
- [16] Fontecilla R., Steihaug T., Tapia R. A., *Convergence Theory for a Class of Quasi-Newton Methods for Constrained Optimization*, SIAM Journal on Numerical Analysis, Vol. 24, No. 5, s. 1133-1151, 1987
- [17] Gill P. E., Murray W., Wright M. H., *Practical Optimization*, Academic Press, London, 402 s., 1981
- [18] Gould N., Orban D., Toint P. L., *CUTer and SifDec: A Constrained and Unconstrained Testing Environment, Revisited*, ACM Transactions on Mathematical Software, Vol. 29, No. 4, s. 373-394, 2003
- [19] Griva I., *Numerical Experiments With an Interior-Exterior Point Method for Nonlinear Programming*, Computational Optimization and Applications, Vol. 29, No. 2, s. 173-195, 2004
- [20] Hamala M., *Nelineárne Programovanie*, Alfa, Bratislava, 2. vydanie, 1976.
- [21] Hamala M., *Prednášky z Nelineárneho programovania*, 2009/2010.
- [22] Hestenes M. R., *Multiplier and Gradient Methods*, Journal of Optimization Theory and Applications, Vol. 4, s. 303-320, 1969.

- [23] Kelley C., *Solving Nonlinear Equations With Newton's Method*, Society for Industrial and Applied Mathematics, 119 s., 2003
- [24] Luenberger D. G., Ye Y., *Linear and Nonlinear Programming*, 3rd edition, Springer, 2008.
- [25] More J., Thuente D., *Line Search Algorithms With Guaranteed Sufficient Decrease*, ACM Transactions on Mathematical Software, Vol. 20, No. 3, s. 286-307, 1994
- [26] Nocedal J., Wright S., *Numerical Optimization*, Springer, 656 s., 2000
- [27] Peng J., Roos C., Terlaky T., *A Logarithmic Barrier Approach to Fischer Function*, Nonlinear Optimization and Applications, Vol. 2, s. 277-298, 1999
- [28] Polyak R., *Modified Barrier Functions (Theory and Methods)*, Mathematical Programming, Vol. 54, s. 177-222, 1992
- [29] Polyak R., *On the Local Quadratic Convergence of the Primal-Dual Augmented Lagrangian Method*, Optimization Methods and Software, Vol. 24, No. 3, s. 369-379, 2009
- [30] Polyak R., Griva I., *1.5-Q-Superlinear Convergence of an Exterior-Point Method for Constrained Optimization*, Journal of Global Optimization, Vol. 40, No. 4, 2008
- [31] Polyak R., Griva I., *Log-Sigmoid Multipliers Method in Constrained Optimization*, Annals of Operations Research, Vol. 101, s. 427-460, 2001
- [32] Polyak R., Griva I., *Primal-Dual Exterior Point Method for Convex Optimization*, Optimization Methods and Software, Vol. 23, No. 1, s. 141-160, 2008
- [33] Polyak R., Griva I., *Primal-Dual Nonlinear Rescaling Method With Dynamic Scaling Parameter Update*, Mathematical Programming, Vol. 106, s. 237-259, 2005
- [34] Polyak R., Griva I., *Primal-Dual Nonlinear Rescaling Method for Convex Optimization*, Journal of Optimization Theory and Applications, Vol. 122, No. 1, s. 111-156, 2004

- [35] Powell M. J. D., *A Method for Nonlinear Constraints in Minimization Problems*, Optimization, Edited by R. Fletcher, Academic Press, New York, s. 283-298, 1969.
- [36] Powell M. J. D., *Algorithms For Nonlinear Constraints That Use Lagrangian Functions*, Mathematical Programming, Vol. 14, s. 224-248, 1978.
- [37] Press H. P., Teukolsky S. A., Vetterling W. T., Flannery B. P., *Numerical Recipes in C: The Art of Scientific Computing*, Cambridge University Press, 3rd Edition, 1256 s., 2007
- [38] Rockafellar R. T., *Convex Analysis*, Princeton University Press, New Jersey, 2nd Edition, 1972
- [39] Rockafellar R. T., *Lagrange Multipliers and Optimality*, SIAM Review, Vol. 35, No. 2, s. 183-238, 1993
- [40] Rockafellar R. T., *The Multiplier Method of Hestenes and Powell Applied to Convex Programming*, Journal of Optimization Theory and Applications, Vol. 12, s. 555-562, 1973.
- [41] Roode J. D., *Generalized Lagrangian Functions and Mathematical Programming*, in Optimization, ed. R. Fletcher, Academic Press, s. 327-338, 1969.
- [42] Schittkowski K., *Test Examples for Nonlinear Programming Codes - All Problems from the Hock-Schittkowski-Collection*, Report, Department of Computer Science, University of Bayreuth, 2009
- [43] Tapia R. A., *On Secant Updates for Use in General Constrained Optimization*, Mathematics of Computation, Vol. 51, No. 183, s. 181-202, 1988

Príloha

A. Newtonova minimalizačná metóda a vyhľadávanie na lúči

V tejto časti budeme uvažovať úlohu na voľnú minimalizáciu v tvare

$$\text{minimalizovať } F(\mathbf{x}), \mathbf{x} \in \mathbb{R}^n \quad (5.1)$$

kde $F : \mathbb{R}^n \rightarrow \mathbb{R}$, $F \in C^2$. Na úvod predpokladajme, že F je rýdzokonvexná.

Majme bod \mathbf{x}^k , ktorý je približným riešením úlohy (5.1). Na okolí tohto bodu budeme approximovať funkciu F Taylorovým polynomom druhého stupňa. Dostávame

$$F(\mathbf{x}) \simeq F(\mathbf{x}^k) + \nabla F(\mathbf{x}^k)^T(\mathbf{x} - \mathbf{x}^k) + \frac{1}{2}(\mathbf{x} - \mathbf{x}^k)^T \nabla^2 F(\mathbf{x}^k)(\mathbf{x} - \mathbf{x}^k). \quad (5.2)$$

Novú approximáciu minima \mathbf{x}^{k+1} definujeme ako bod minimalizujúci (5.2). Derivovaním (5.2) a dosadením \mathbf{x}^{k+1} dostávame

$$\nabla F(\mathbf{x}^k) + \nabla^2 F(\mathbf{x}^k)(\mathbf{x}^{k+1} - \mathbf{x}^k) = 0,$$

z čoho máme

$$\mathbf{x}^{k+1} = \mathbf{x}^k - \nabla^2 F(\mathbf{x}^k)^{-1} \nabla F(\mathbf{x}^k). \quad (5.3)$$

Tento iteračný predpis určuje jeden krok *klasickej Newtonovej metódy*. Uvedená metóda patrí do triedy metód, v ktorých sa nový iteračný krok určuje ako

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \lambda^k \mathbf{s}^k,$$

pre voľbu

$$\mathbf{s}^k = -\nabla^2 F(\mathbf{x}^k)^{-1} \nabla F(\mathbf{x}^k), \quad \lambda^k = 1. \quad (5.4)$$

Vidíme, že Newtonovský smer \mathbf{s}^k je *spádový*, čiže platí $\nabla F(\mathbf{x}^k)^T \mathbf{s}^k < 0$ (kedže $\nabla^2 F(\mathbf{x}^k)$ je kladne definitná). Výsledná metóda však nemusí byť spádová v zmysle

$F(\mathbf{x}^{k+1}) < F(\mathbf{x}^k)$. Preto základom modifikovanej Newtonovej metódy bude regulácia kroku λ^k .

Do polovice 60-tych rokov sa presadzovala myšlienka optimalizácie kroku λ^k , dôsledkom čoho bolo nutné riešiť minimalizačnú úlohu

$$\lambda^k = \arg \min_{\lambda > 0} \{F(\mathbf{x}^k + \lambda \mathbf{s}^k)\},$$

ktorá je však časovo náročná. Aj preto sa neskôr od tejto požiadavky upúšťalo a cieľom bolo hľadať „približne optimálny“ krok. Kvôli zabráneniu akceptovateľnosti príliš malých alebo veľkých krovov boli neskôr formulované podmienky, ktoré musí krok λ^k spĺňať. Takýmito podmienkami sú napr. *silné Wolfeho podmienky*

$$F(\mathbf{x}^k + \lambda^k \mathbf{s}^k) \leq F(\mathbf{x}^k) + c_1 \lambda^k \nabla F(\mathbf{x}^k)^T \mathbf{s}^k, \quad (5.5)$$

$$|\nabla F(\mathbf{x}^k + \lambda^k \mathbf{s}^k)^T \mathbf{s}^k| \leq c_2 |\nabla F(\mathbf{x}^k)^T \mathbf{s}^k|, \quad (5.6)$$

pre $0 < c_1 < c_2 < 1$. Podmienka (5.5) zabezpečuje hornú hranicu pre krok λ^k , podmienka (5.6) naopak dolnú hranicu. Konštanty c_1, c_2 je možné voliť napr. $c_1 = 10^{-4}$, $c_2 = 0.9$ [26]. Sústava podmienok (5.5), (5.6) zabezpečí, že krok λ^k bude ležať blízko optimálneho kroku. Známym algoritmom na hľadanie krovov spŕajajúcich (5.5), (5.6) je algoritmus J. Morého a D. Thuenteho [25]. Pre iné algoritmy pozri napr. [9].

Doteraz sme predpokladali ostrú konvexnosť funkcie F . Pre funkcie, ktoré nie sú konvexné už nie je iterácia 5.3 dobre definovaná: smer \mathbf{s}^k nemusí byť spádový, a ak neexistuje $\nabla^2 F(\mathbf{x}^k)^{-1}$, tak \mathbf{s}^k nie je ani definovaný. Tieto problémy môžu nastať aj v prípade konvexných funkcií, ak je matica $\nabla F(\mathbf{x}^k)$ singulárna alebo takmer singulárna. V tomto prípade je možné modifikovanú Newtonovu metódu opraviť uvažovaním matice $\nabla^2 F(\mathbf{x}^k) + \mathbf{E}^k$ namiesto $\nabla^2 F(\mathbf{x}^k)$, kde \mathbf{E}^k je diagonálna matica zvolená tak, že $\nabla^2 F(\mathbf{x}^k) + \mathbf{E}^k$ je zaručene kladne definitná (niektorí autori uvažujú $\mathbf{E}^k = \mu^k \mathbf{I}$, $\mathbf{E}^k = 0$ ak $\nabla^2 F(\mathbf{x}^k)$ je dostatočne kladne definitná). Známym algoritmom na hľadanie matice \mathbf{E}^k je algoritmus GMW81 (pozri [26], [17]) založený na modifikovanom Choleskeho rozklade matice $\nabla^2 F(\mathbf{x}^k)$ (algoritmus v skutočnosti vykoná Choleskeho rozklad $\nabla^2 F(\mathbf{x})$ tak, že platí $\mathbf{L}\mathbf{L}^T = \nabla^2 F(\mathbf{x}) + \mathbf{E}$).

V tejto práci sa často stretávame s potrebou riešiť problém (5.1), k čomu využívame modifikovanú Newtonovu metódu nasledovnej implementácie.

Krok 1 : Inicializácia. Určí konštantu ε a polož $k = 0$.

Krok 2 : AK $\|\nabla F(\mathbf{x}^k)\| < \varepsilon$, STOP, **Výstup** : \mathbf{x}^k .

Krok 3 : Nájdi \mathbf{s}^k z rovnice $(\nabla^2 F(\mathbf{x}^k) + \mathbf{E}^k)\mathbf{s}^k = -\nabla F(\mathbf{x}^k)$, kde \mathbf{E}^k je určená pomocou GMW81 algoritmu.

Krok 4 : Nájdi približné riešenie úlohy $\lambda^k = \arg \min_{\lambda > 0} \{F(\mathbf{x}^k + \lambda \mathbf{s}^k)\}$ spĺňajúce (5.5), (5.6).

Krok 5 : Polož $\mathbf{x}^{k+1} = \mathbf{x}^k + \lambda^k \mathbf{s}^k$, $k = k + 1$, CHOĎ NA KROK 2.

Na riešenie sústavy v kroku 3 používame Choleskeho rozklad, krok 4 kvôli jednoduchosti riešime Brentovou metódou [6] (testovali sme aj algoritmus MoreThuente [25]). Kódy všetkých procedúr sú priložnené k diplomovej práci.

B. Výsledky testovania príkladov CUTEr

V tabuľkách uvádzame výsledky algoritmov dosiahnuté pri riešení vybranej vzorky príkladov zo zborníka CUTEr. Ku každému príkladu pridávame jeho názov a takisto rozmery (n - počet premenných, m - počet nerovníc, p - počet rovníc). Údaje o absolútnej odchýlke bodov \bar{x}, \bar{y} od optimálnych riešení nahradíme údajom o funkčnej hodnote v bode \bar{x} ($\bar{f} = f(\bar{x})$). Požadovaná tolerancia bola nastavená na $\varepsilon = 10^{-8}$.

VÝSLEDKY TESTOVANIA CUTEr PRÍKLADOV							
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť
úloha '3PK', $n = 30, m = 30, p = 0$							
AL_NR	1.720E+00	3.849E-12	9.481E-13	2.737E-231	4	4	0.231
AL_ROC1	1.720E+00	2.821E-12	0.000E+00	2.737E-231	1	1	0.106
AL_ROC2	1.720E+00	2.821E-12	0.000E+00	8.043E-270	1	1	0.007
FIS1	1.720E+00	1.614E-06	6.642E-15	8.043E-270	32	32	0.419
FIS2	1.720E+00	7.174E-07	1.085E-12	8.043E-270	3	3	0.140
POL	1.720E+00	9.174E-12	1.853E-09	8.043E-270	3	4	0.140
úloha 'AIRCRFTA', $n = 8, m = 0, p = 8$							
AL_NR	0.000E+00	6.777E-14	0.000E+00	2.388E-16	1	7	0.030
AL_ROC1	0.000E+00	6.777E-14	0.000E+00	2.388E-16	1	7	0.039
AL_ROC2	0.000E+00	6.777E-14	0.000E+00	2.388E-16	1	7	0.034
FIS1	0.000E+00	1.000E-13	0.000E+00	2.388E-16	4	4	0.054
FIS2	0.000E+00	6.777E-14	0.000E+00	2.388E-16	1	7	0.031
POL	0.000E+00	6.777E-14	0.000E+00	2.388E-16	1	7	0.030
úloha 'AIRCRFTB', $n = 8, m = 0, p = 3$							
AL_NR	1.672E-25	4.397E-11	0.000E+00	1.368E-14	1	23	0.104
AL_ROC1	1.672E-25	4.397E-11	0.000E+00	1.368E-14	1	23	0.123
AL_ROC2	1.672E-25	4.397E-11	0.000E+00	1.368E-14	1	23	0.127
FIS1	8.109E-01	6.994E-14	0.000E+00	0.000E+00	34	34	0.257
FIS2	1.672E-25	4.397E-11	0.000E+00	1.368E-14	1	23	0.110
POL	1.672E-25	4.397E-11	0.000E+00	1.368E-14	1	23	0.107
úloha 'AIRPORT', $n = 84, m = 210, p = 0$							
AL_NR	4.795E+04	3.683E-11	7.262E-09	2.247E-12	17	33	0.323
AL_ROC1	4.795E+04	1.013E-10	5.643E-09	2.184E-12	21	42	0.419
AL_ROC2	4.795E+04	1.933E-12	3.208E-12	4.747E-16	15	36	0.405
FIS1	4.795E+04	1.592E-12	7.512E-10	8.597E-14	13	13	0.321
FIS2	4.795E+04	4.547E-12	1.177E-09	9.164E-14	14	29	0.297
POL	4.795E+04	2.274E-12	3.260E-12	4.747E-16	13	34	0.314

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTEr

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'ALLINQP', $n = 100, m = 134, p = 28$								
AL_NR	-9.159E+00	1.026E-11	2.254E-09	2.515E-09	14	36	0.292	
AL_ROC1	-9.159E+00	6.479E-09	9.171E-09	5.949E-09	11	34	0.288	
AL_ROC2	-9.159E+00	5.551E-16	2.637E-17	2.220E-16	3	14	0.164	
FIS1	-9.159E+00	2.578E-10	5.346E-14	2.220E-16	10	10	0.208	
FIS2	-9.159E+00	9.290E-16	4.628E-14	2.220E-16	9	17	0.134	
POL	-9.159E+00	2.876E-11	5.012E-11	8.242E-11	9	18	0.113	
úloha 'AUG2DCP', $n = 220, m = 220, p = 110$								
AL_NR	3.040E+02	6.106E-10	2.897E-09	1.955E-09	12	22	0.487	
AL_ROC1	3.040E+02	3.026E-13	2.260E-09	1.578E-11	13	19	0.554	
AL_ROC2	3.040E+02	2.331E-15	3.955E-16	8.882E-16	6	12	0.437	
FIS1	-	-	-	-	-	-	-	
FIS2	3.040E+02	6.982E-12	3.620E-12	1.934E-10	8	11	0.389	
POL	3.040E+02	1.308E-10	2.887E-10	7.195E-09	8	13	0.347	
úloha 'AVGASA', $n = 8, m = 26, p = 0$								
AL_NR	-4.632E+00	1.545E-13	4.811E-09	2.438E-09	9	13	0.050	
AL_ROC1	-4.632E+00	6.917E-14	3.125E-09	1.282E-09	11	14	0.059	
AL_ROC2	-4.632E+00	8.882E-16	1.371E-16	5.551E-17	3	6	0.035	
FIS1	-4.632E+00	4.237E-12	1.081E-14	7.757E-17	8	8	0.105	
FIS2	-4.632E+00	1.422E-10	1.055E-14	8.043E-270	5	9	0.035	
POL	-4.632E+00	1.518E-10	4.758E-10	5.392E-10	5	10	0.038	
úloha 'AVGASB', $n = 8, m = 26, p = 0$								
AL_NR	-4.483E+00	4.885E-14	7.231E-09	2.527E-09	11	17	0.073	
AL_ROC1	-4.483E+00	1.423E-13	8.562E-09	3.327E-09	12	16	0.068	
AL_ROC2	-4.483E+00	8.882E-16	9.889E-17	2.220E-16	4	7	0.041	
FIS1	-4.483E+00	4.289E-09	1.131E-14	1.212E-16	8	8	0.102	
FIS2	-4.483E+00	1.948E-09	1.138E-14	2.737E-231	5	10	0.040	
POL	-4.483E+00	7.994E-15	3.841E-14	1.477E-14	6	12	0.044	
úloha 'BDEXP', $n = 500, m = 500, p = 0$								
AL_NR	0.000E+00	2.058E-18	5.034E-15	2.737E-231	3	3	5.085	
AL_ROC1	7.670E-28	9.971E-27	0.000E+00	2.737E-231	1	1	1.593	
AL_ROC2	7.670E-28	9.971E-27	0.000E+00	2.737E-231	1	1	1.598	
FIS1	4.036E-07	1.414E-08	9.238E-16	8.043E-270	74	74	24.486	
FIS2	0.000E+00	3.078E-15	1.589E-12	2.737E-231	3	3	3.428	
POL	8.286E-28	2.639E-21	1.279E-18	2.737E-231	3	3	2.344	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'BIGGSB1', $n = 1000, m = 1998, p = 0$								
AL_NR	1.500E-02	7.995E-13	2.155E-09	5.887E-09	12	28	79.869	
AL_ROC1	1.500E-02	1.006E-13	2.430E-09	8.043E-270	4	11	35.235	
AL_ROC2	1.500E-02	2.220E-16	0.000E+00	2.737E-231	3	9	58.144	
FIS1	1.500E-02	9.516E-09	7.390E-13	8.043E-270	37	37	181.446	
FIS2	1.500E-02	6.366E-09	4.101E-13	2.737E-231	8	13	44.048	
POL	1.500E-02	2.166E-11	1.458E-13	7.324E-13	8	14	55.102	
úloha 'BOX2', $n = 3, m = 0, p = 1$								
AL_NR	8.027E-19	9.126E-10	0.000E+00	1.033E-10	1	5	0.068	
AL_ROC1	8.027E-19	9.126E-10	0.000E+00	1.033E-10	1	5	0.039	
AL_ROC2	8.027E-19	1.727E-09	0.000E+00	1.033E-10	1	5	0.023	
FIS1	1.829E-16	1.244E-09	0.000E+00	0.000E+00	13	13	0.118	
FIS2	8.027E-19	9.126E-10	0.000E+00	1.033E-10	1	5	0.019	
POL	8.027E-19	9.126E-10	0.000E+00	1.033E-10	1	5	0.019	
úloha 'CONGIGMZ', $n = 3, m = 5, p = 0$								
AL_NR	2.800E+01	2.758E-10	2.448E-09	8.043E-270	11	31	0.128	
AL_ROC1	1.968E+02	1.846E+20	3.969E+21	4.407E+02	99	5000	25.742	
AL_ROC2	1.968E+02	1.846E+20	3.969E+21	4.407E+02	99	5000	25.558	
FIS1	2.800E+01	3.259E-12	1.602E-14	7.105E-15	8	8	0.094	
FIS2	2.800E+01	9.907E-16	7.423E-15	2.737E-231	5	16	0.075	
POL	2.800E+01	3.794E-15	7.106E-15	7.105E-15	6	18	0.078	
úloha 'CVXBQP1', $n = 100, m = 200, p = 0$								
AL_NR	2.272E+02	3.411E-13	6.497E-09	2.179E-12	8	10	0.075	
AL_ROC1	2.272E+02	4.263E-14	2.031E-09	1.042E-11	16	19	0.150	
AL_ROC2	2.273E+02	0.000E+00	0.000E+00	2.737E-231	8	11	0.119	
FIS1	2.273E+02	1.142E-10	1.107E-11	6.106E-15	5	5	0.108	
FIS2	2.273E+02	1.421E-14	1.004E-11	6.467E-15	7	9	0.078	
POL	2.272E+02	1.421E-13	2.192E-09	7.567E-13	7	11	0.077	
úloha 'CVXQP1', $n = 100, m = 200, p = 50$								
AL_NR	1.159E+04	4.614E-10	1.845E-09	2.061E-09	13	39	0.312	
AL_ROC1	1.159E+04	1.771E-10	9.889E-09	3.787E-11	19	30	0.264	
AL_ROC2	1.159E+04	1.771E-10	9.889E-09	3.787E-11	19	30	0.481	
FIS1	1.159E+04	2.274E-13	2.716E-11	1.125E-14	11	11	0.332	
FIS2	1.159E+04	7.958E-13	2.990E-11	2.177E-14	12	35	0.318	
POL	1.159E+04	2.274E-13	1.388E-11	8.692E-12	12	38	0.289	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'CVXQP2', $n = 100, m = 200, p = 25$								
AL_NR	8.121E+03	1.637E-11	5.525E-10	2.414E-10	11	27	0.196	
AL_ROC1	8.121E+03	1.307E-11	9.028E-09	2.308E-11	19	26	0.225	
AL_ROC2	8.121E+03	1.137E-13	1.380E-14	8.882E-16	10	17	0.172	
FIS1	8.121E+03	1.787E-12	3.383E-11	1.324E-14	17	17	0.543	
FIS2	8.121E+03	1.137E-13	4.861E-11	2.637E-14	12	28	0.425	
POL	8.121E+03	2.274E-13	2.734E-13	1.021E-14	10	26	0.195	
úloha 'DTOC1L', $n = 598, m = 0, p = 400$								
AL_NR	4.254E-01	5.770E-15	0.000E+00	8.051E-10	6	9	4.669	
AL_ROC1	4.254E-01	5.770E-15	0.000E+00	8.051E-10	6	9	5.335	
AL_ROC2	4.254E-01	8.246E-09	0.000E+00	5.653E-09	3	7	5.175	
FIS1	4.254E-01	1.372E-10	0.000E+00	9.714E-17	9	9	3.318	
FIS2	4.254E-01	2.040E-10	0.000E+00	9.021E-17	6	7	2.203	
POL	4.254E-01	8.209E-13	0.000E+00	1.211E-12	4	8	4.128	
úloha 'DUAL1', $n = 85, m = 170, p = 1$								
AL_NR	3.501E-02	7.149E-10	1.793E-12	3.868E-12	18	35	0.358	
AL_ROC1	3.501E-02	9.507E-14	5.090E-10	1.125E-09	11	30	0.297	
AL_ROC2	3.501E-02	2.352E-15	6.753E-19	2.164E-16	6	16	0.239	
FIS1	3.501E-02	6.103E-10	6.653E-13	1.341E-09	12	12	0.342	
FIS2	3.501E-02	1.113E-12	6.654E-13	1.341E-09	18	20	0.315	
POL	3.501E-02	2.852E-15	1.949E-15	8.003E-14	16	37	0.366	
úloha 'DUAL2', $n = 96, m = 192, p = 1$								
AL_NR	3.373E-02	3.772E-11	1.640E-09	1.815E-09	16	30	0.305	
AL_ROC1	3.373E-02	2.754E-14	1.248E-09	3.076E-11	10	19	0.267	
AL_ROC2	3.373E-02	1.638E-15	1.323E-22	3.886E-16	7	11	0.244	
FIS1	3.373E-02	1.614E-10	8.864E-14	1.094E-13	8	8	0.274	
FIS2	3.373E-02	2.033E-15	8.716E-14	2.914E-14	14	17	0.236	
POL	3.373E-02	1.235E-15	7.739E-15	5.377E-13	12	29	0.364	
úloha 'EXPQUAD', $n = 120, m = 20, p = 0$								
AL_NR	-3.626E+06	6.594E-12	8.207E-10	2.726E-11	7	22	0.133	
AL_ROC1	-3.626E+06	5.912E-12	2.461E-09	6.214E-11	13	36	0.216	
AL_ROC2	-3.626E+06	8.422E-08	0.000E+00	8.043E-270	6	29	0.180	
FIS1	-	-	-	-	-	-	-	
FIS2	-3.626E+06	6.366E-12	2.263E-13	1.776E-15	5	20	0.167	
POL	-3.626E+06	6.995E-12	9.914E-11	3.306E-12	6	21	0.117	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLADOV								
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'GENHS28', $n = 10, m = 0, p = 8$								
AL_NR	9.272E-01	3.775E-15	0.000E+00	2.066E-09	6	6	0.022	
AL_ROC1	9.272E-01	3.775E-15	0.000E+00	2.066E-09	6	6	0.022	
AL_ROC2	9.272E-01	2.220E-16	0.000E+00	1.110E-16	3	3	0.014	
FIS1	9.272E-01	1.186E-10	0.000E+00	1.110E-16	7	7	0.094	
FIS2	9.272E-01	5.274E-16	0.000E+00	1.665E-16	4	4	0.010	
POL	9.272E-01	2.220E-15	0.000E+00	3.331E-16	4	4	0.012	
úloha 'GILBERT', $n = 50, m = 1, p = 1$								
AL_NR	2.115E+01	1.055E-14	9.442E-17	7.392E-09	11	15	0.127	
AL_ROC1	2.115E+01	9.881E-15	0.000E+00	7.391E-09	11	15	0.100	
AL_ROC2	2.115E+01	1.946E-12	0.000E+00	2.550E-12	5	10	0.068	
FIS1	2.115E+01	6.112E-09	4.414E-16	1.962E-09	13	13	0.107	
FIS2	2.115E+01	2.929E-11	4.391E-16	3.304E-12	5	9	0.050	
POL	2.115E+01	1.359E-10	9.158E-20	9.411E-10	6	10	0.054	
úloha 'GOULDQP3', $n = 699, m = 1398, p = 349$								
AL_NR	2.028E+00	4.815E-10	1.354E-10	6.475E-09	11	24	25.149	
AL_ROC1	2.028E+00	4.968E-11	2.750E-10	2.795E-10	7	32	36.587	
AL_ROC2	2.028E+00	3.057E-15	0.000E+00	3.553E-15	6	31	51.286	
FIS1	2.018E+00	3.338E-08	8.978E-03	4.375E-03	99	99	232.696	
FIS2	1.962E+00	1.174E-04	1.758E-02	1.074E-01	99	108	255.446	
POL	2.028E+00	2.693E-13	2.766E-12	2.301E-10	11	22	41.565	
úloha 'GRIDGENA', $n = 578, m = 780, p = 188$								
AL_NR	1.920E+03	4.448E-13	1.840E-29	4.494E-09	9	10	6.857	
AL_ROC1	1.920E+03	3.389E-13	0.000E+00	3.297E-09	8	9	6.894	
AL_ROC2	1.920E+03	2.953E-09	0.000E+00	5.421E-20	3	4	5.423	
FIS1	1.920E+03	6.067E-09	4.152E-14	1.023E-19	5	5	4.136	
FIS2	1.920E+03	7.200E-10	3.088E-13	7.790E-18	4	5	3.508	
POL	1.920E+03	7.239E-13	3.439E-26	7.565E-13	5	6	4.241	
úloha 'GRIDNETA', $n = 180, m = 41, p = 148$								
AL_NR	9.524E+01	3.624E-13	3.701E-09	2.821E-09	15	21	0.330	
AL_ROC1	9.524E+01	2.010E-13	3.448E-09	2.208E-10	14	15	0.341	
AL_ROC2	9.524E+01	2.010E-13	3.448E-09	2.208E-10	14	15	0.557	
FIS1	9.524E+01	4.000E+00	8.533E-15	2.665E-15	99	99	9.702	
FIS2	9.524E+01	2.070E-13	1.002E-14	9.194E-16	9	15	0.638	
POL	9.524E+01	7.097E-11	2.328E-10	1.744E-10	8	15	0.400	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'GRIDNETI', $n = 924, m = 308, p = 484$								
AL_NR	8.787E+01	1.866E-11	2.194E-09	5.103E-09	16	28	65.608	
AL_ROC1	8.787E+01	5.262E-14	2.330E-09	4.822E-09	14	28	69.615	
AL_ROC2	8.787E+01	5.262E-14	2.330E-09	4.822E-09	14	28	87.785	
FIS1	8.787E+01	9.058E-09	1.394E-13	5.025E-11	10	10	13.095	
FIS2	8.787E+01	5.284E-14	1.715E-13	5.024E-11	12	16	26.136	
POL	8.787E+01	8.882E-16	5.356E-15	1.245E-12	12	22	49.327	
úloha 'HANGING', $n = 308, m = 180, p = 12$								
AL_NR	-6.202E+02	7.553E-12	5.016E-09	1.776E-10	11	35	2.226	
AL_ROC1	-5.378E+00	2.050E-02	6.931E+11	4.035E+00	99	2281	139.942	
AL_ROC2	-5.378E+00	2.050E-02	6.931E+11	4.035E+00	99	2281	171.870	
FIS1	-6.202E+02	3.858E-11	1.129E-11	1.833E-11	26	26	2.278	
FIS2	-6.202E+02	1.180E-13	3.260E-13	1.910E-14	6	26	1.568	
POL	-6.202E+02	1.625E-11	2.438E-09	2.891E-10	7	25	1.360	
úloha 'HAGER1', $n = 201, m = 0, p = 101$								
AL_NR	8.808E-01	2.976E-11	0.000E+00	5.868E-09	10	10	0.166	
AL_ROC1	8.808E-01	2.976E-11	0.000E+00	5.868E-09	10	10	0.201	
AL_ROC2	8.808E-01	4.783E-13	0.000E+00	2.620E-13	3	3	0.093	
FIS1	8.808E-01	8.049E-09	0.000E+00	2.198E-14	11	11	0.386	
FIS2	8.808E-01	3.152E-09	0.000E+00	2.254E-14	5	5	0.112	
POL	8.808E-01	4.018E-11	0.000E+00	3.115E-13	6	7	0.101	
úloha 'HART6', $n = 6, m = 12, p = 0$								
AL_NR	-3.323E+00	3.022E-12	9.918E-10	8.043E-270	4	7	0.020	
AL_ROC1	-3.323E+00	3.475E-14	0.000E+00	8.043E-270	2	6	0.023	
AL_ROC2	-3.323E+00	3.475E-14	0.000E+00	2.737E-231	2	6	0.027	
FIS1	-6.687E-04	7.078E-03	2.670E-15	8.043E-270	99	99	0.944	
FIS2	-3.323E+00	6.155E-11	5.277E-15	2.737E-231	4	7	0.021	
POL	-3.323E+00	2.640E-10	8.164E-13	8.043E-270	4	7	0.021	
úloha 'HS11', $n = 2, m = 1, p = 0$								
AL_NR	-8.498E+00	1.219E-12	6.953E-09	2.280E-09	5	11	0.100	
AL_ROC1	-8.498E+00	2.665E-15	7.035E-09	2.307E-09	8	14	0.081	
AL_ROC2	-8.498E+00	1.763E-11	4.166E-12	1.366E-12	4	11	0.054	
FIS1	-8.498E+00	1.423E-09	1.022E-13	3.353E-14	7	7	0.075	
FIS2	-8.498E+00	6.350E-13	5.552E-14	1.821E-14	4	10	0.042	
POL	-8.498E+00	2.984E-11	7.733E-09	2.536E-09	4	8	0.041	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'HS14', $n = 2, m = 1, p = 1$								
AL_NR	1.393E+00	2.531E-14	3.501E-09	6.940E-09	10	14	0.049	
AL_ROC1	1.393E+00	2.087E-14	6.913E-09	3.744E-09	10	13	0.047	
AL_ROC2	1.393E+00	1.023E-08	6.187E-09	3.350E-09	4	9	0.034	
FIS1	1.393E+00	7.162E-09	4.309E-12	2.333E-12	6	6	0.059	
FIS2	1.393E+00	6.861E-09	7.936E-09	4.298E-09	4	7	0.021	
POL	1.393E+00	1.386E-13	1.597E-12	2.048E-12	5	7	0.017	
úloha 'HS34', $n = 3, m = 8, p = 0$								
AL_NR	-8.340E-01	8.107E-10	1.915E-11	2.737E-231	5	19	0.086	
AL_ROC1	—	—	—	—	—	—	—	
AL_ROC2	—	—	—	—	—	—	—	
FIS1	-8.340E-01	1.280E-11	1.516E-14	3.233E-13	11	11	0.203	
FIS2	-8.340E-01	1.443E-15	8.837E-15	1.723E-13	8	15	0.067	
POL	-8.340E-01	4.408E-39	7.715E-17	2.737E-231	5	23	0.126	
úloha 'HS37', $n = 3, m = 8, p = 0$								
AL_NR	-3.456E+03	8.572E-10	1.023E-12	7.105E-15	5	9	0.051	
AL_ROC1	-3.456E+03	6.730E-11	3.070E-12	8.043E-270	8	12	0.071	
AL_ROC2	-3.456E+03	2.842E-14	0.000E+00	8.043E-270	6	10	0.069	
FIS1	-1.597E-22	1.436E-09	1.864E-16	8.043E-270	19	19	0.296	
FIS2	-3.456E+03	1.188E-11	1.029E-12	8.043E-270	4	8	0.044	
POL	-3.456E+03	0.000E+00	2.053E-48	8.043E-270	6	10	0.044	
úloha 'HS44NEW', $n = 10, m = 16, p = 0$								
AL_NR	-1.500E+01	3.115E-11	4.050E-11	2.871E-12	5	12	0.095	
AL_ROC1	-1.500E+01	8.334E-12	1.545E-09	8.043E-270	6	10	0.085	
AL_ROC2	-1.500E+01	8.334E-12	1.545E-09	2.737E-231	6	10	0.112	
FIS1	-3.000E+00	1.859E-10	4.111E-15	2.737E-231	11	11	0.189	
FIS2	-1.500E+01	4.121E-11	1.066E-12	4.547E-13	4	9	0.074	
POL	-1.500E+01	7.105E-15	1.338E-14	8.043E-270	6	10	0.066	
úloha 'HS100', $n = 7, m = 4, p = 0$								
AL_NR	6.806E+02	6.065E-09	5.377E-12	4.121E-13	4	18	0.125	
AL_ROC1	6.806E+02	5.556E-11	7.152E-11	8.043E-270	4	17	0.111	
AL_ROC2	6.806E+02	4.558E-08	6.159E-11	1.053E-10	3	16	0.111	
FIS1	6.806E+02	2.931E-12	3.311E-14	2.376E-14	14	14	0.214	
FIS2	6.806E+02	1.230E-10	1.669E-09	4.449E-09	4	14	0.086	
POL	6.806E+02	3.553E-14	6.666E-13	5.342E-13	4	20	0.121	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLADOV							
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť
úloha 'HS108', $n = 9, m = 14, p = 0$							
AL_NR	-8.660E-01	5.868E-09	8.302E-10	3.990E-13	8	175	1.033
AL_ROC1	-8.660E-01	4.596E-11	7.834E-10	2.513E-10	6	86	0.511
AL_ROC2	-8.660E-01	4.596E-11	7.834E-10	2.513E-10	6	86	0.562
FIS1	-8.660E-01	2.844E-09	1.892E-12	2.471E-12	69	69	0.981
FIS2	-8.660E-01	3.113E-09	3.868E-15	7.617E-20	6	25	0.151
POL	-8.660E-01	4.520E-10	1.274E-13	2.283E-13	6	32	0.170
úloha 'HS113', $n = 10, m = 8, p = 0$							
AL_NR	2.431E+01	5.204E-10	8.898E-11	2.409E-11	4	20	0.117
AL_ROC1	2.431E+01	1.879E-11	2.910E-09	1.036E-09	4	19	0.114
AL_ROC2	2.431E+01	3.143E-08	3.417E-10	2.856E-10	3	18	0.123
FIS1	2.431E+01	4.370E-13	9.369E-15	1.421E-14	11	11	0.137
FIS2	2.431E+01	5.760E-13	1.052E-11	5.064E-10	4	19	0.109
POL	2.431E+01	6.598E-09	6.803E-11	5.143E-11	3	23	0.125
úloha 'HS118', $n = 15, m = 59, p = 0$							
AL_NR	6.648E+02	4.736E-12	1.460E-10	1.795E-10	4	24	0.245
AL_ROC1	6.648E+02	1.348E-12	1.502E-09	3.050E-10	3	42	0.396
AL_ROC2	6.648E+02	2.802E-13	1.502E-09	3.050E-10	3	42	0.393
FIS1	1.798E+02	4.341E+01	1.359E+03	1.466E+03	99	99	2.062
FIS2	6.648E+02	5.286E-11	2.383E-11	4.471E-10	4	23	0.173
POL	6.648E+02	1.776E-15	8.943E-11	3.007E-10	4	27	0.214
úloha 'JANNSON3', $n = 200, m = 402, p = 1$							
AL_NR	1.985E+02	1.378E-08	7.892E-09	1.430E-10	13	17	0.646
AL_ROC1	1.985E+02	1.081E-13	0.000E+00	1.193E-10	6	10	0.573
AL_ROC2	1.985E+02	2.220E-16	0.000E+00	1.089E-16	5	8	0.969
FIS1	1.985E+02	9.427E-09	1.780E-13	1.119E-15	5	5	1.084
FIS2	1.985E+02	3.708E-14	1.781E-13	1.366E-16	6	7	0.932
POL	1.985E+02	1.452E-08	1.737E-15	4.187E-14	7	11	0.785
úloha 'MATRIX2', $n = 6, m = 6, p = 0$							
AL_NR	1.754E-13	3.687E-09	3.399E-13	1.244E-14	22	35	0.222
AL_ROC1	1.717E-11	4.272E-18	3.959E-11	3.175E-12	6	28	0.181
AL_ROC2	4.830E-19	1.387E-09	4.316E-20	3.285E-09	5	14	0.109
FIS1	1.154E-16	4.234E-09	2.234E-16	2.693E-17	6	6	0.089
FIS2	1.375E-09	3.419E-09	6.438E-09	2.331E-09	13	17	0.050
POL	1.844E-22	1.506E-18	3.688E-22	6.329E-10	91	127	0.893

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIPI	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'MCCORMCK', $n = 1000, m = 2000, p = 0$								
AL_NR	-9.137E+02	1.018E-13	6.904E-09	6.377E-09	5	8	24.310	
AL_ROC1	-9.137E+02	8.882E-13	8.139E-10	8.043E-270	4	48	152.777	
AL_ROC2	-9.137E+02	1.554E-15	0.000E+00	8.043E-270	4	48	170.406	
FIS1	-9.137E+02	4.090E-12	4.521E-13	2.737E-231	11	11	183.033	
FIS2	-9.137E+02	1.812E-14	5.334E-13	2.737E-231	4	7	61.171	
POL	-9.137E+02	9.473E-10	1.099E-09	1.176E-09	4	6	26.415	
úloha 'MINC44', $n = 51, m = 66, p = 40$								
AL_NR	4.297E-02	4.477E-13	3.357E-13	3.043E-09	11	62	0.466	
AL_ROC1	4.297E-02	1.976E-11	0.000E+00	8.681E-09	8	55	0.443	
AL_ROC2	1.177E+10	5.961E+20	4.436E+23	8.233E+06	99	4918	64.134	
FIS1	-	-	-	-	-	-	-	
FIS2	4.297E-02	4.120E-11	2.778E-14	5.242E-11	9	69	0.545	
POL	4.297E-02	4.636E-11	2.393E-18	6.885E-11	7	39	0.268	
úloha 'OBSTCLBM', $n = 529, m = 882, p = 88$								
AL_NR	6.519E+00	5.650E-10	1.855E-09	6.603E-09	11	29	12.581	
AL_ROC1	6.519E+00	1.998E-14	7.468E-10	2.825E-10	7	27	13.721	
AL_ROC2	6.519E+00	1.388E-16	6.291E-18	6.939E-18	4	21	16.531	
FIS1	6.519E+00	5.489E-10	4.362E-13	2.431E-13	9	9	6.940	
FIS2	6.519E+00	2.474E-13	4.530E-13	2.760E-13	11	16	9.670	
POL	6.519E+00	2.220E-16	4.760E-14	9.748E-14	12	24	15.045	
úloha 'OPTCTRL6', $n = 302, m = 0, p = 203$								
AL_NR	5.039E+03	1.177E-08	0.000E+00	9.108E-09	17	32	1.687	
AL_ROC1	5.039E+03	1.177E-08	0.000E+00	9.108E-09	17	32	1.995	
AL_ROC2	5.039E+03	2.774E-11	0.000E+00	1.632E-15	16	78	5.547	
FIS1	5.039E+03	3.881E-07	0.000E+00	1.161E-13	5	5	0.670	
FIS2	5.039E+03	1.356E-06	0.000E+00	5.348E-11	11	14	1.486	
POL	5.039E+03	2.728E-11	0.000E+00	1.570E-11	17	43	3.580	
úloha 'PRIMAL1', $n = 325, m = 86, p = 0$								
AL_NR	-3.501E-02	4.197E-09	3.325E-11	3.517E-09	9	28	3.124	
AL_ROC1	-3.501E-02	7.653E-14	1.851E-09	5.899E-09	4	23	2.671	
AL_ROC2	-3.501E-02	5.375E-17	9.325E-18	4.510E-17	4	23	3.469	
FIS1	-3.501E-02	5.803E-11	9.985E-13	1.664E-09	11	11	1.928	
FIS2	-3.501E-02	6.940E-14	4.006E-13	1.050E-09	13	19	2.101	
POL	-3.501E-02	2.220E-16	3.086E-16	1.950E-13	9	31	3.242	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLAĐOV								
ALG	\bar{f}	GRAD	KOMP	PRIIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'PRIMAL2', $n = 649, m = 97, p = 0$								
AL_NR	-3.373E-02	1.116E-09	5.588E-11	6.158E-10	8	23	14.301	
AL_ROC1	-3.373E-02	1.082E-13	2.048E-09	5.639E-09	4	16	9.780	
AL_ROC2	-3.373E-02	1.061E-15	9.579E-18	5.594E-17	3	15	10.657	
FIS1	-3.373E-02	1.452E-10	7.419E-14	1.570E-13	7	7	1.316	
FIS2	-3.373E-02	6.217E-15	7.597E-14	1.570E-13	9	15	6.148	
POL	-3.373E-02	1.173E-09	1.583E-13	2.879E-15	8	25	14.609	
úloha 'S268', $n = 5, m = 5, p = 0$								
AL_NR	4.657E-10	7.335E-10	9.273E-10	2.737E-231	5	9	0.044	
AL_ROC1	1.455E-11	7.276E-12	0.000E+00	2.737E-231	2	3	0.020	
AL_ROC2	1.455E-11	7.276E-12	0.000E+00	2.737E-231	2	3	0.024	
FIS1	-3.638E-12	7.269E-07	3.207E-17	2.737E-231	8	8	0.098	
FIS2	1.091E-11	1.231E-06	4.332E-18	2.737E-231	4	7	0.028	
POL	1.091E-11	7.724E-07	5.103E-18	2.737E-231	4	7	0.029	
úloha 'SIMPLLPA', $n = 2, m = 4, p = 0$								
AL_NR	1.000E+00	1.360E-12	2.138E-11	1.395E-11	5	10	0.048	
AL_ROC1	1.000E+00	0.000E+00	0.000E+00	8.043E-270	3	5	0.024	
AL_ROC2	1.000E+00	0.000E+00	0.000E+00	2.737E-231	3	5	0.026	
FIS1	1.000E+00	5.946E-09	4.634E-12	4.633E-12	8	8	0.094	
FIS2	1.000E+00	6.521E-09	1.954E-11	1.855E-11	3	5	0.023	
POL	1.000E+00	0.000E+00	1.278E-11	1.278E-11	5	7	0.027	
úloha 'STCQP1', $n = 1025, m = 2025, p = 510$								
AL_NR	2.618E+04	9.026E-09	1.508E-75	2.331E-15	13	20	69.879	
AL_ROC1	2.618E+04	8.754E-12	2.184E-09	2.437E-11	18	24	101.653	
AL_ROC2	2.618E+04	8.754E-12	2.184E-09	2.437E-11	18	24	272.656	
FIS1	2.618E+04	8.160E-12	8.930E-13	2.454E-14	9	9	72.859	
FIS2	2.618E+04	9.030E-11	7.999E-11	1.598E-10	14	23	124.668	
POL	2.618E+04	4.547E-13	2.242E-12	1.039E-12	10	18	85.552	
úloha 'UBH1', $n = 909, m = 606, p = 612$								
AL_NR	1.116E+00	1.811E-11	1.970E-10	2.700E-11	6	6	12.935	
AL_ROC1	1.116E+00	2.080E-11	0.000E+00	1.625E-09	5	5	15.141	
AL_ROC2	1.116E+00	2.129E-12	0.000E+00	3.837E-13	3	3	12.521	
FIS1	1.799E+00	2.219E-05	2.657E-13	1.812E-13	99	99	222.896	
FIS2	1.116E+00	6.341E-10	2.691E-13	4.214E-13	5	5	11.556	
POL	1.116E+00	2.189E-06	0.000E+00	7.310E-13	99	102	307.053	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

VÝSLEDKY TESTOVANIA CUTER PRÍKLADOV								
ALG	\bar{f}	GRAD	KOMP	PRIP	počet iterácií	\sum mikroit.	časová náročnosť	
úloha 'WACHBIEG', $n = 3, m = 2, p = 2$								
AL_NR	1.000E+00	1.021E-14	3.602E-10	7.063E-10	7	15	0.056	
AL_ROC1	1.000E+00	3.828E-13	2.450E-09	4.903E-09	6	15	0.064	
AL_ROC2	1.000E+00	8.882E-16	3.218E-16	1.110E-15	4	14	0.066	
FIS1	1.000E+00	1.522E-09	1.158E-12	2.316E-12	10	10	0.106	
FIS2	1.000E+00	1.611E-11	7.514E-12	1.503E-11	4	11	0.039	
POL	1.000E+00	1.887E-15	2.449E-16	8.882E-16	5	15	0.055	

Tabuľka 5.7: Súhrnné výsledky pre testovanie úloh zo zbierky CUTER, pokračovanie

C. Zdrojový kód

Záverečnú časť prílohy venujeme zdrojovým kódom algoritmov. Vypíšeme niektoré z algoritmov uvažovaných v časti 4.2 aj s ich subprocedúrami, celý súbor funkcií je možné nájsť na priloženom médiu. Funkcie v jazyku C je nutné pred použitím skompilovať pomocou MATLABovského príkazu mex s parametrom -lmwblas kvôli zaradeniu hlavičiek funkcií z knižnice BLAS.

Generátor úloh z časti 4.1

```

1 function [varargout] = generu3quad(n, m, ma, mq, dist, condin, gdiag, outopt)
2 % 
3 % [x,hat,u,hat,v,hat,D,G,h,Gin,hin,rin,A,b,heq,beg,x0] =
4 % generu3quad(n,m,ma,mg,meq,dist,rcond,gdiag,outopt)
5 % funkcia generuje ulohu bikvadratickeho konvezneho programovania v tvare
6 % min 0.25*(x'*D*x).^2 + 0.5*x'*G*x + h'*x
7 % za podmienok 0.5*x'*Gin*x + h'*x
8 % A*x >= b
9 % Aeqrx == beq
10 %
11 %
12 %
13 % Vstupne parametre specifikuju rozsah ulohy: n - pocet premennych,
14 % m - pocet ohraniceni v tvare nerovnosti, mq - pocet kvadratickych
15 % ohraniceni (mq <= m), ma je pocet ohraniceni v tvare nerovnosti,
16 % ktore su aktívne v bode optimiza (predpoklada sa ma < min(m,n-mq),
17 % mq - pocet ohraniceni v tvare rovníc, dist - voliteľny parameter, ktorý
18 % uvedie určidelenosť strotovacieho bodu x0 od optimálneho riešenia ulohy
19 % x,hat. V prípade nedostatku dist je vo vystupe x0 = [], rcond =
20 % pozadované cislo podmienenosť matice D, G, pripadne Gin, gdiag -
21 % uveda, ci su matice Gin diagonálne, alebo nie,
22 % options - struktura udávajúca vystupne nastavenia generátora
23 %
24 % STRUKTURA VYSTUPU:
25 % Vstupna premenna outopt specifikuje format vystupu. Volba 's' spôsobí,
26 % že v prípade mq = 0 alebo m = 0 budú vo vystupe vyniesane v,hat, a, eq,
27 % beg (ak mq = 0), pripadne u,hat, A, b, Gin, hin, rin (ak m = 0).
28 % Teda napr. pri vôle outopt = 's' a mq = 0 je vystup vo forme
29 % [x,hat, u,hat, D, G, h, A, b, Gin, hin, rin, x0].
30 %
31 % kontrola vstupnych parametrov
32 if nargin < 9
33     outopt = 's';
34     if nargin < 8
35         gdiag = [];
36         if nargin < 6
37             dist = [];
38             if nargin < 5
39                 meq = 0;
40                 if nargin < 4
41                     mq = 0;
42                     if nargin < 3
43                         error('Príliš malo vstupnych parametrov, minimum je 3');
44                     end
45                 end
46             end
47         end
48     end
49     end
50 end
51 %
52 % kontrola chybnych vstupov
53 if isempty(n) || isempty(m) || isempty(ma) || isempty(meq) || isempty(mq)
54     error('Vstupne parametre n, m, ma, mq a meq musia byt cíelne udaje');
55 end
56 if isempty(condin)
57     condin = 5;
58 end
59 %
60 n = max(0, floor(n)); m = max(0, floor(m));
61 ma = max(0, floor(ma)); mq = max(0, floor(mq));
62 mq = max(0, floor(mq)); dist = max(0, dist);
63 condin = max(2, condin); rcondin = 1/condin;
64 if mq + ma > n
65     error('Pocet aktivnych ohraniceni (%d) presahuje pocet premennych (%d)', ...
66     mq + ma, n);
67     meq + ma, n);
68 end
69 if mq > m
70     error('Ziadany pocet kvadratickych ohraniceni presahuje ich pocet')
71 end
72 %
73 % kontrola vstupnych parametrov, prípad. keď je požiadavka na vynemeanie
74 % nepožiadanej vystupovej formy
75 outoptindex = strmpy(outopt, 's');
76 if outoptindex
77     if meq && nargin > 11
78         error('Pocet vstupnych parametrov je nekonzistentny so vstupom ulohy')
79     end
80     if ~m && nargin > 8
81         error('Pocet vstupnych parametrov je nekonzistentny so vstupom ulohy')
82     end
83     if ~mq && ~m && nargin > 4
84         error('Pocet vstupnych parametrov je nekonzistentny so vstupom ulohy')
85     end
86 else
87     if nargin > 14
88         error('Pocet vstupnych parametrov je nekonzistentny so vstupom ulohy')
89     end
90 end
91 %
92 % globálne parametre
93 rozsah = 10;
94 dens = 0.4;
%
```

```

95 deep = 16;
96 % matice A, leq a vektor b, beg
97 % heuristika pre urcenia lmin na zaklade znalosti condn
98 lmax = log(condn + 1);
99 lmin = lmax*condn;
100 lvec = lmin + (lmax-lmin)*rand(n, 1);
102 indl = rand([1, n]); indu = rand([1, n]);
103 while indl == indu && n > 1
104     indu = rand([1, n]);
105 end
106 lvec(indl) = lmin; lvec(indu) = lmax;
107
108 % generovanie optimallych rieseni, u_hat ma rovnomerne rozdelene
109 % nulove a nemulove hodnoty
110 mct = m - ma; mat = ma; p = ma/m;
111 x_hat = rand([-rozsa], rozsa, n, 1); % optimale riesenie
112 v_hat = rand([-rozsa], rozsa); meq, 1); % multiplicator rovnosti
113 u_hat = rand(m, 1); % multiplicator nerovnosti
114
115 for i = 1:m
116     if u_hat(i) < p
117         mat = mat - 1;
118     else
119         mt = mt - 1; u_hat(i) = 0;
120     end
121     p = mat/(mat+mt);
122 end
123 P = u_hat > 0;
124 u_hat(p) = floor(0.75*rozsa*rand(nnz(p), 1)) + 1;
125
126 % generovanie matric ulohy
127 D = 1*vec;
128 G = full(sprandsym(n, dens, rcondn, 2));
129
130 if pdiag == 0
131     Gin = zeros(n, n*nq);
132 else
133     Gin = zeros(n, mq);
134 end
135 bin = zeros(n, mq);
136 rin = zeros(m, 1);
137 tgrad = zeros(m, n);
138 for i=1:nq
139     if godiag == 0
140         Gin(:, -(i-1)+1:n) = -full(sprandsym(n, dens, rcondn, 2));
141         hin(:, i) = rand([-0.5*rozsa], 0.5*rozsa, n, 1);
142         rin(i) = 0.5*x_hat.*gin(:, i); rin(:, i)=x_hat;
143         tgrad(i, :) = (Gin(:, n:(i-1)+1:n).*x_hat + hin(:, i));
144     else
145         lvec = lmin + (lmax-lmin)*rand(n, 1);
146         indl = rand([1, n]); indu = rand([1, n]);
147         while indl == indu && n > 1
148             indu = rand([1, n]);
149         lvec(indl) = lmin; lvec(indu) = lmax;
150         Gin(:, i) = -lvec;
151         hin(:, i) = rand([-0.5*rozsa], 0.5*rozsa, n, 1);
152         rin(i) = 0.5*x_hat.*gin(:, i).*x_hat + hin(:, i).*x_hat;
153         tgrad(i, :) = (Gin(:, i).*x_hat + hin(:, i));
154     end
155 end
156
157
158 % matice A, leq a vektor b, beg
159 A = rand([-0.5*rozsa], 0.5*rozsa, n);
160 b = Ax_hat;
161 tgrad(m+1:m, :) = A;
162 leq = rand([-0.5*rozsa], 0.5*rozsa, n);
163 beq = Aeq*x_hat;
164
165 % dopocitanie zrynych vektorov
166 pt = p1:mq; p = P(mq+1:m);
167
168 rin(pt) = rin(pt) - 0.75*rozsa*rand(size(rin(pt)))*10^(-deep/2);
169 b(pt) = b(pt) - 0.75*rozsa*rand(size(b(pt)))*10^(-deep/2);
170 h = tgrad.*u_hat - Aeq*v_hat - (G*x_hat + (x_hat.*P).*x_hat));
171
172 % ak je zadane dist, dopocitanie startovacieho bodu zo
173 if isempty(dist)
174     pon = 2*rozsa*rand(n, 1) - rozsa;
175     x0 = x_hat + (abs(dist)/norm(pon))*pon;
176 else
177     x0 = [];
178 end
179
180 % uprava vystupnych parametrov
181 varargout{1} = x_hat;
182
183 k, 1, vystup = [x_hat, D, G, h, x0]
184 if 'm' ~meq && outopindex
185     varargout{2} = G; varargout{3} = h; varargout{4} = x0;
186     return
187 end
188 if ~m
189     % 2a. vystup = [x_hat,v_hat,D,G,h,Aeq,b,u,x0]
190     % 2b. vystup = [x_hat,[v_hat,D,G,h,Gin,hin,rin,A,b,u,x0]
191     if outopindex
192         varargout{2} = v_hat; varargout{3} = D;
193         varargout{4} = G; varargout{5} = h;
194         varargout{6} = Aeq; varargout{7} = beq;
195         varargout{8} = x0;
196         return
197     end
198 end
199 if ~meq
200     % 3a. vystup = [x_hat,u_hat,D,G,h,Gin,hin,rin,A,b,u,x0]
201     % 3b. vystup = [x_hat,u_hat,[D,G,h,Gin,hin,rin,A,b,u,x0]
202     if outopindex
203         varargout{2} = u_hat; varargout{3} = D;
204         varargout{4} = G; varargout{5} = h;
205         varargout{6} = rin; varargout{7} = A;
206         varargout{8} = b; varargout{9} = x0;
207         return
208     end
209 end
210 end
211
212 % [x_hat,u_hat,v_hat,D,G,h,Gin,hin,rin,A,b,Aeq,beq,x0]
213 varargout{2} = u_hat; varargout{3} = v_hat;
214 varargout{4} = D; varargout{5} = G;
215 varargout{6} = h; varargout{7} = Gin;
216 varargout{8} = hin; varargout{9} = rin;
217 varargout{10} = A; varargout{11} = b;
218 varargout{12} = Aeq; varargout{13} = beq;
219 varargout{14} = x0;

```

Funkcia Rockafellarovo algoritmu (rieši úlohy vytvorené generátorom úloh, verzia na riešenie úloh CUTER je analogická a možno ju nájsť na priloženom médiu).

```

1 function [kopt, yopt, zopt, output] = ulohu3SPR.bq_q(D,g,h,Gin,hin,rin,...;
2     A,b,Aeq,beq,lb,ub,x0,varargin)
3 % kontrola nezadanych vstupov
4 if nargin < 14
5   nargin = 14;
6   options = [];
7   if nargin < 13
8     x0 = [];
9     if nargin < 12
10    ub = [];
11    if nargin < 11
12      lb = [];
13    end
14  end
15 end
16 end
17 b = b(:);
18 h = h(:);
19 ub = ub(:);
20 beq = beq(:);
21 rin = rin(:);
22 % kontrola rozmerov ulohy
23 n = max([length(g), length(h), length(lb), length(ub)]);
24 m = max([length(rin), length(h), length(b)]);
25 mq = length(rin);
26 ml = length(b);
27 meq = length(beq);
28 m = ml + mq;
29
30 if (~all(size(A) == [ml, n]) && ~isempty(A) )
31   error('Matica A ma nespravny rozmer ,ocakavam (%u x %u)', ml, n);
32 elseif (~all(size(Aeq) == [meq,n]) && ~isempty(Aeq) )
33   error('Matica AEQ ma nespravny rozmer ,ocakavam (%u x %u)', meq, n);
34 elseif (Length(D) ~= n && ~isempty(D)) || (Length(h) ~= n && ~isempty(h))
35   error('Diagonálna matica D alebo vektor H maju nespravny rozmer');
36 elseif ~all(size(hin) == [n, mq])
37   error('Matica HIN ma nespravny rozmer');
38 end
39 % nastavenia parametrov
40 if ~isempty(varargin)
41   options = setoptions(varargin);
42 end
43 end
44 defaults = struct('Tolerancia', 1e-06, 'HlavniteIteracieMax', 100, ...
45 'NewtonovskeIteracieMax', 50, 'RParametre', 10, 'CasVypoctov', ...
46 'MaxDiferenc', 1, 'UpdateMethod', 1, 'HlavniteIteracieMax', defaults);
47 MaxDiferenc = setting(options, 'NewtonovskeIteracieMax', 'defaulsts');
48 MaxMainIter = setting(options, 'NewtonovskeIteracieMax', 'defaults');
49 MaxNewtonIter = setting(options, 'NewtonovskeIteracieMax', 'defaults');
50 r = setting(options, 'RParametre', defaults);
51 epsilon = setting(options, 'Tolerancia', defaults);
52 Time = setting(options, 'CasVypoctov', defaults);
53 verb = setting(options, 'Verbosity', defaults);
54 MultMethod = setting(options, 'UpdateMethod', defaults);
55 PSI_I = 'psi_-I_PIR';
56 PSI_E = 'psi_E';
57
58 % v pripade, ze A, Aeq, b, beq su prazdne, prenastavime na spravne
59 % rozmerky krovci nasobenu
60 if isempty(A)
61   A = zeros(0, n);
62 end
63 if isempty(Aeq)
64   Aeq = zeros(0, n);
65 end
66 if isempty(b)
67   b = zeros(0, 1);
68 end
69 if isempty(beq)
70   beq = zeros(0, 1);
71 end
72 [Aap, bap] = kontrolaohr(lb, ub, n);
73 A = [A; Aap];
74 b = [b; bap];
75 b = [];
76
77 % zistime rozmerky kvadratickych ohraniceni
78 size_g = size(Gin, 2);
79 if size_g == mq
80   gding = 1;
81 elseif size_g == mq*
82   gding = 0;
83 else
84   error('Matica Gin nema pozadované rozmer');
85 end
86
87 % stvoracie hodnoty multiplikatorov
88 y = ones(m, 1);
89 z = zeros(meg, 1);
90 if isempty(x0)
91   x = zeros(n, 1);
92 elseif length(x0) ~= n
93   x = zeros(n, 1);
94   warning('Uloha03.x:Orozmer', 'Vektor x0 ma iby rozmer ako n, zacinam z [0; ... ;0]');
95 else
96   x = x0(:);
97 end
98
99 output = struct('HlavniteIteracie', 0, 'NewtonovskeIteracie', 0, ...
100 'Tolerancia', epsilon, 'Merit', Inf, 'VypoctovyCas', 0);
101 NewtonIterationCount = 0;
102 NormTypeMerit = Inf; NormTypeMerit = 'max';
103
104 % sputstanie merania casu
105 if Time ~= 0
106   tic;
107 end
108
109 % vypocty pociatocnych dat v x0
110 [g, H] = LagrAug_quad(y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r, ...
111 PSI_E, PSI_I, 'gradness');
112 [fin, feq, Jin, Jeq] = const_quad(x,Gin,hin,rin,A,b,Aeq,beq,gdiag);
113 mrtt = merit_comp(fin, feq, y, NormTypeMerit);
114 con_viol = const_viol(jin, feq, y, NormTypeMerit);
115 rho_des = 0.25;
116 r_max = 5*1e5;
117 r_max_mupd = 6;
118 l = 0.9;
119 min_col = 0.25;
120 gral_toll_cis = max(sqrt(norm(h, NormType)), 1);
121 gral_toll_flag = sqrt(r) * gral_toll_cis;
122 grad_flag = 0;
```

```

123 mrt_.rthreshold = 1; % miesto prepnutia odhadov
124 % test pouzitia metody odhadu
126 if MultiMethod == 1
127 net = 1;
128 elseif MultiMethod == 2
129 if mrt < mrt_rthreshold
130 met = 2;
131 else
132 met = 1;
133 end
134 else
135 error('Neznana metoda odhadu parametrov');
136 end
137 % hlavna iteracia, ich pocet je limitovany parametrom MaxMainIter
139 %
140 % Proces updatovania multiplikatorov funguje nasledovne : ak zvolene
141 % nastavene UPDATEMETHOD = 1, potom sa pouziva 1st order update, pri
142 % volbe UPDATEMETHOD = 2 sa najprv pouzije 1st order, a ked morit
143 % dostatočne poriadne (pod hodnotu MET_THRESHOLD), zache sa pouzivat
144 % 2nd order update
145 %
146 for k=1:MaxMainIter % HLAVNA ITERACIA
147 %
148 % kontrola optimality: ak je merit funkcia dostatočne mala (t.j.
149 % porusena prípustnosť a podmienka komplementarity
150 % dosahuju male hodnoty, takisto norma gradientu je relativne mala),
151 % ukoncime algoritmus
152 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
153 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
154 if verb
155 fprintf('<n*****>%s<n*****> ITERACIA %u *****\n', k);
156 fprintf('<n*****> A KOMPLEMENTARTA> %e\n', mrt);
157 fprintf('<n*****> KLAS. LAGR. > %e\n', norm(LagClas quad(x, ...
158 y, z, D, G, h, Gin, hin, rin, A, b, Aeq, beq, grad), NormType));
159 end
160 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
161 %
162 % skalovany gradient v merit funkciu
163 if mrt < epsilon && grad_flag
164 break
165 end
166 %
167 % stanovime terminacne kriterium pomocou rozdielu medzi prediktorm
168 % multiplikatora a konkretnym multiplikatorom, predejny prislusym
169 % Penalizacnym parametrom r
170 [yt, zt] = mult_update(x,y,z,fin,req,Jin,req,r,g,H,PSI_I,met);
171 upd_diff = norm([yt - y; zt - z], NormType );
172 tol = min(1 / r * upd_diff, min_tol);
173 tol = min(1 / r * upd_diff, min_tol);
174 tol = min(1 / r * upd_diff, min_tol);
175 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
176 if verb
177 fprintf('<TERM. KRITERIUM NEUTON M.> %e\n', tol + epsilon...);
178 fprintf('GREJ ROLL %e\n', grej_rol);
179 fprintf('<NORMA GRADIENTU AUGLAG F.> %e\n', norm(g, NormType));
180 fprintf('<PODZITY ODDIAV MULTIPLIKATOROV> %u\n', met);
181 fprintf('<*****> NEWTON. ITERACIA *****\n');
182 end
183 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
184 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
185 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
186 for j=1:MaxNewtonIter % ZACIATOK NEWTONSKEJ ITERACIE
187 %
188 % podmienka konvergencie pre Newtonovsky iteraciu, ak je norma
189 % gradientu AngLag funkcie mensia ako prislusna tolerancia, vzd
190 % vsak treba vykonat aspon jednu iteraciu
191 if (norm(g, NormType) < tol + epsilon * gtol) && j > 1;
192 break
193 end
194 %
195 % spocitane Newtonovsky krok S, krok LAM stanovime ciastoconou
196 % minimalizaciu na luci X + (AMS niektooru z dostupnych metod
197 % BBENTZERO alebo MORTRIENTE), a definujeme X_{k+1} =
198 % X_{-k} + LAM_{-k} * S_QR
199 %
200 %
201 %
202 %
203 % Newtonovsky smes
204 s = -H \ g;
205 %
206 % vypocet kroku LAM splinajuceho Wolfeho kriterium aj silnu
207 % Goldsteinova podmienku
208 lam = brentzero(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,s,...;
209 PSI_E, PSI_I);
210 %
211 % morethalf(x,y,z,D,G,h,Gin,hin,in,A,b,Aeq,beq,r,s,...;
212 % PSI_E, PSI_I);
213 %
214 % upravime primary vektor z
215 x = x + lam*s;
216 %
217 % prepocitanie hodnoty ohraniceni a zvolime novu terminaciu
218 % kriterium, dopocitame gradient v novom bode a spustime
219 % novu iteraciu
220 %
221 % prepocitanie gradient a Hesssov matice
222 [g, H] = Lagrag_quadr(x,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,...;
223 PSI_E, PSI_I, gradness);
224 [fin, seq, Jin, Jeg] = const_quad(x,Gin,hin,rin,A,b,Aeq,beq,gradag);
225 [yt, zt] = mult_update(x,y,z,fin,req,Jin,req,r,g,H,PSI_I,met);
226 %
227 % terminacie kriterium
228 upd_diff = norm([yt - y; zt - z], NormType );
229 tol = min(1 / r * upd_diff, min_tol);
230 %
231 tol = min(1 / r * upd_diff, min_tol);
232 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
233 if verb
234 fprintf('<TERM. KRITERIUM %e\n', tol + epsilon*grtol);
235 fprintf('<DLZKA KROKU> %f, <NORMA GRAD. AUGLAG. F.> %e\n', ...
236 lam, norm(g, NormType));
237 end
238 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
239 '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPISY '%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
240 %
241 % pocitadlo Newtonskych iteraci
242 NewtonIterationCount = NewtonIterationCount + 1;
243 %
244 end % KONIEC NEWTONSKEJ ITERACIE
245 %
246 % Update multiplikatorov, 1st order update
247 %
248 %
249 %
250 z = zt;
251 y = yt;
252 %
253 %
254 % Zistime, ci treba zvysit hodnotu penalizacneho parametra r na
255 % zaklade poklesu neprispustnosti aktualneho bodu, nova hodnota
256 % parameteru bude z intervalu [R_{CURRENT}, R_{MAX}]

```

```

324 output.Merit = mrtt;
325
326 %
327 %-----%
328
329 function [lyt, zt] = mult_update(x,y,z,fin,eq,Jin,Jeq,r,g,H,PSI_I,met)
330
331 % funkcia pocita prislusny oahad multiplikatorov pre metodu PHR.
332 % Parameter MET specifikuje porazdovani volbu odhadu multiplikatorov
333 % MET> 1 : vykona sa oahad prveho radu
334 % 2 : vykona sa oahad druhho radu
335 %
336 % predpokladaa sa, ze PSI_E = 'psi_E'.
337
338 % 1st order update
339
340 yt = -feval(PSI_I, r*fin, y, 'der1');
341 zt = feval('psi_E',r*eq, z, 'der1');
342
343 if met == 2
344 % pozadovany je oahad druheho radu
345 n = length(x);
346 m = length(y);
347 meq = length(z);
348
349 % vypnone varningy suvisace so singularnymi maticami a pokusime sa
350 % o oahad mult. 2nd order
351 lastwarn('');
352 warning off 'MATLAB:singularMatrix';
353 warning off 'MATLAB:nearlySingularMatrix';
354
355 % vypocet potrebnych matic v definicii 2nd order update
356 D1 = [feval(PSI_I, r*fin, y, 'der2_xiu'); zeros(meq,1)];
357 D2 = [feval(PSI_I, r*fin, y, 'der2_num') / r; zeros(meq,1)];
358 der = [feval(PSI_I, r*fin, y, 'der1_mu') / r; eq];
359 M = Diwones(1,n).*Jin; Jeq];
360
361 % vyskuzane vypocet
362 res = [lyt zt] + (M*(H\yt) - diag(D2))\ (agr - M*(H\g));
363 [~, widl] = lastwarn;
364 if isempty(widl)
365 % matice je regularna, spocitanie oahadu 2. radu
366 yr = max(0, res(1,m)); yr = yr(:);
367 end
368 % navrat warningovych nastaveni
369 % warning on 'MATLAB:singularMatrix';
370 warning on 'MATLAB:nearlySingularMatrix';
371 catch err
372 % doslo k inemu erroru, vyzvolame ho znova
373 warning on 'MATLAB:singularMatrix';
374 warning on 'MATLAB:nearlySingularMatrix';
375 rethrow(err);
376
377 end
378 and
379
380 function [bap, bap] = kontrolaohr(lb, ub, varc)
381
382 if isempty(lb) && isempty(ub)
383 Aap = [];
384 bap = [];
385
386 return;
387
388 ub = ub(:);
389 lb = lb(:);
390

```

```

391 if length(ub) > varc
392   warning('kontrola:ubRozmer', 'length(ub) > pocet premennych, prebytne ignorujem.');
393   ub = ub(1:varc);
394 elseif length(ub) < varc
395   ub = [ub; Inf*ones(varc - length(ub), 1)];
396 end
397
398 if length(lb) > varc
399   warning('kontrola:lbRozmer', 'length(lb) > pocet premennych, prebytne ignorujem.');
400   lb = lb(1:varc);
401 elseif length(lb) < varc
402   lb = [lb; -Inf*ones(varc - length(lb), 1)];
403 end
404
405 if any(lb>ub)
406   error('Nekonzistentne ohranicenia, niektore z dolnych ohraniceni jesu vacsie ako hornie');
407 elseif any(lb == Inf)
408   error('Dolne ohranicenie nemoze byt Inf');
409 elseif any(ub == -Inf)
410   error('Horne ohranicenie nemoze byt -Inf');
411 end
412
413 Iden = eye(varc);
414 Kap = [Iden(isfinite(lb), :); -Iden(isfinite(ub), :)];
415 Bap = [lb(isfinite(lb)); -ub(isfinite(ub))];
416
417 PSI_I = setting(options, 'PsiFunction', defaults);
418 PSI_E = 'psiE';
419
420 % v pripade, ze A, Aeq, b, beq su prazdne, prenastavime na spravne
421
422 if nargin < 12
423   options = [];
424   A = zeros(0, n);
425 end
426 if isempty(Aeq)
427   Aeq = zeros(0, n);
428 end
429 if isempty(b)
430   b = zeros(0, 1);
431 end
432 if isempty(beq)
433   beq = zeros(0, 1);
434 end
435
436 % zistime rozmer kvaratickych ohraniceni
437 size_E = size(Gin, 2);
438 if size_E == mq
439   gdiag = 1;
440 else
441   size_E-g == mq*n
442   gdiag = 0;
443 end
444
445 % startovacie hodnoty mnoziskov
446 y = ones(mn, 1);
447 z = zeros(meg, 1);
448
449 error('Matica Gin nema pozadované rozmer');
450
451 m = ml + mq;
452 ml = length(ml);
453 mq = length(mq);
454
455 if all(size(A) == [ml, mq]) && ~isempty(A)
456   error('Matica A ma nespravný rozmer, očakávaný (%u x %u)', ml, mq);
457 elseif (~all(size(Aeq) == [mq,n]) && ~isempty(Aeq))
458   error('Matica AEQ ma nespravný rozmer, očakávaný (%u x %u)', meg, n);
459 elseif (length(D) == n && ~isempty(D)) || (length(h) == n && ~isempty(h))
460   error('Diagonálna matice D alebo vektor H majú nespravný rozmer');
461 elseif 'allsize(hin) == [n, mq]')
462   error('Matica HIN ma nespravný rozmer');
463
464 % nastavenia parametrov
465 options = setoptions(varargin);
466
467 defaults = struct('Tolerancia', 1e-06, 'HlavnIteraciMax', 100, ...
468   'Newtonovsketeraciifax', 50, 'Rparameter', 10, 'CasNypoctov', ...
469   'Verbosity', 0, 'PsiFunction', 'psiI.hyp');
470 MatlabIter = setting(options, 'HlavnIteraciifax', 'Rparameter', 'psiI.hyp');
471 MatlabIter = setting(options, 'Newtonovsketeraciifax', 'Rparameter', 'psiI.hyp');
472 pen_k = setting(options, 'Rparameter', 'defalts');
473 epsilon = setting(options, 'Tolerancia', 'defalts');
474 Time = setting(options, 'CasNypoctov', 'defalts');
475 Verb = setting(options, 'Verbosity', 'defalts');
476
477 output = struct('HlavnIteracie', 0, 'Newtonovskiteracie', 0, 'Tolerancia', epsilon, ...
478   'Merit', Inf, 'VypoctovyCas', 0);
479 MainIteration = 0;
480 NestOnIteration = 0;
481 NormType = Inf; NormTypeMerit = 'max';
482
483 warning('UlohaUS:xRozmer', 'Vektor x0 ma iny rozmer ako n, zacinam z [0; ... ; 0]');
484 else
485   x = x0(:);
486 end
487
488 output = struct('HlavnIteracie', 0, 'Newtonovskiteracie', 0, 'Tolerancia', epsilon, ...
489   'Merit', Inf, 'VypoctovyCas', 0);
490 MainIteration = 0;
491 NestOnIteration = 0;
492 NormType = Inf; NormTypeMerit = 'max';
493
494 % spustenie meranie casu

```

Funkcia Polyakovho a Grivovo algoritmu

Funkcia modifikovaného Fischerovho algoritmu.

```

129 % skalovany gradient v merit funkciu
130 if mrt < epsilon && grad_flag
131 break
132 end
133 % podla identifikatora FLAG urcime, ktery algoritmus sa bude vykonavat
134 if flag == 1
135 % vyzkame Fischerov cast algoritmu pre klasicku Lagr. funkciu
136 [Lx, Lxx] = LagrClas.quad(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beg,'gradness');
137
138 % nadzemne korakcie [lx, dy, dz] riesenim Fischerovj sustavy
139 [dx,dy,dz],prec = solveSystem(Lxx,Lx,fin,feq,jin,Jeq,y,r,ru,PSI_1);
140 NewtonIt = NewtonIt + 1;
141
142 % predikcia noveho bodu
143 x = x + lam*dx;
144 % minimalizacia normy Fischerovej sustavy
145 sner = [dx;dy;dz];
146 lam = 1;
147
148 % predikcia noveho bodu
149 x = max(0, y + lam*dy);
150 z = z + lam*dx;
151
152 % vypocitanie hodnotu ohranienci a zisitme zmenu priupustnosti
153 % a komplementarity v novom bode
154 [fin,req,jn,jed] = const.quad(x,Gin,hin,rin,A,b,Aeq,beg,godiag);
155 mrt = merit.comp(fin,req,'',NormType);
156 con_viol = const_viol(fin, req, NormType);
157
158 %VYPLISY
159 %VYPLISY
160 if verb
161 fprintf('<RESIENSTV RIESENIA SUSTAVY> %e\n', prec);
162 end
163 %NOVA HODNOTA PRIUPUSTNOSTI
164 %VYPLISY
165
166 % budeme minimalizovať AugLag v x a použijeme 1st order multiplifier
167 % update, zvyčajne prychiď niekolko iteracií sa výkona v rečimej
168 % minimalizácií, polyká merit funkcia náhoda dosťetocne mala
169 % stanovime terminacie pomocou rozdielu medzi prediktorm
170 % penalizacnym parametrom r
171 % stanovime terminacie pomocou rozdielu medzi prediktorm
172 % penalizacnym multiplifikatorom, predeleny prislušnym
173 % penalizacnej, polyká merit funkcia náhoda dosťetocne mala
174 yt = - feval(PSI_E,r*fin,y,der1);
175 zt = feval(PSI_E,r*feq,z,der1);
176 upd.diff = norm( lyt - y; zt - zl, NormType );
177 toll = min(l / r * upd.diff, min_toll);
178
179 [Lx, Lxx] = LagrAug_quad(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beg,r,...);
180 PSI_E,PSI_I,'gradness');
181
182 %VYPLISY
183 %VYPLISY
184 if verb
185 fprintf('<TERM. KRITERIUM NEWTON M > %e\n', toll + epsilon*...
186 'grel_tol);', norm(Lx, NormType));
187 fprintf('<TERM. KRITERIUM AUGLAG F > %e\n', norm(Lx, NormType));
188 fprintf('<***** NEWTON . ITERACIA *****\n');
189
190 %Zistime, ci treba zvysit hodnotu penalizacneho parametra r na
191 %zaklade poklesu neprispustnosti aktualneho bodu, nova hodnota
192 for j=1:MaxNewtonIter % ZACIATOK NEWTONOVSKej ITERACIE
193 % porusenie prispustnosti
194 % podmienka konvergencie pre Newtonovsku iteraciu
195 if verb
196 fprintf('<ITERACIA %d>\n', j);
197 end
198 if (norm(Lx, NormType) < toll + epsilon * grel_tol) && j > 1
199 if verb
200 fprintf('<POZDADOVANA PRESNOST DOSIERNUTA>\n');
201 end
202 break
203 end
204 % spociatane Newtonovsky krok S, krok LAM stanovime ciastochou
205 % minimalizacioni na luci X + LAM* niektorou z dosupujuch metod
206 % (BRENTZERO alebo MORETHENTE), a definujeme X_{k+1} =
207 % = X_{k} + LAM_{k}*S_{k}
208
209 % upravime primary vektor x
210 x = x + lam*sner;
211 % Newtonovsky smer
212 dx = chol_solve(Lxx, Lx);
213 % vypocet kroku LAM spinajuceho Wolfeho kriterium aj silnu
214 % Golstainova podmienka
215 % lam = brentzero(y,D,G,h,Gin,hin,rin,A,b,Aeq,beg,r,dr,...);
216 lam = brentzero(y,D,G,h,Gin,hin,rin,A,b,Aeq,beg,r,dr,...);
217
218 % preocitame hodnoty ohranienci a zvolime nové terminacie
219 % kriterium, dopocitame gradient v novom bode a spustime
220 % novu iteraciu
221 [fin, feq] = const.quadd(x,Gin,hin,rin,A,b,Aeq,feq,fdiag);
222 % preocitame gradient v novom bode
223 % kriterium, dopocitame gradient v novom bode a spustime
224 % novu iteraciu
225 yt = - feval(PSI_E,r*fin,'',der1);
226 zt = feval(PSI_E,r*feq,z,'',der1);
227
228 % terminacie kriterium
229 % terminacie kriterium v novom bode
230 upd.diff = norm( lyt - y; zt - zl, NormType );
231 toll = min(l / r * upd.diff, min_toll);
232
233 % preocitame gradient v novom bode
234 [Lx, Lxx] = LagrAug_quad(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,feq,r,...);
235 PSI_E,PSI_I,'gradness'),);
236
237 %VYPLISY
238 if verb
239 fprintf('<TERM. KRITERIUM> %e, toll + epsilon*grel_tol);
240 fprintf('<DLZA KROKU> %f, <NORMA GRAD. AUGLAG. F.> %e\n', ...
241 lan, norm(Lx, NormType));
242 end
243 % Update multiplifikatorov, 1st order update
244 zt = zt;
245 y = yt;
246
247 % pocitalo Newtonovskych iteracií
248 NewtonIt = NewtonIt + 1;
249
250 % KONIEC NEWTONOVSKej ITERACIE
251
252 %Zistime, ci treba zvysit hodnotu penalizacneho parametra r na
253 %zaklade poklesu neprispustnosti aktualneho bodu, nova hodnota
254 % porusenie prispustnosti
255 % zaokrouhlenie do celych cisiel
256 % zaklade poklesu neprispustnosti aktualneho bodu, nova hodnota
257 % parametra bude z intervalu [R_CURRENT, R_MAX]
258 con_viol_old = con_viol;
259 con_viol = const_viol(fin, fed, NormTypeMerit); % porusenie prispustnosti
260 rho = con_viol / con_viol_old; % podiel poruseni
261 % cakali sme vasici pokles
262 if rho > rho_des

```

```

317 zopt = z;
318 output.HlavneIteracie = k - 1;
319 output.MeritonoskeIteracie = Newtonite;
320 output.Merit = mrt;
321
322 function ret = normstep(alpha,x,y,z,smer,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,mu,%
323 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
324 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
325 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
326 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
327 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
328 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
329 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% VYPLSY %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
330 xnew = x+alpha*smer(1:n);
331 ynew = y+alpha*smer(n+1:n+m);
332 znew = z+alpha*smer(n+m+1:n+m+meq);
333
334 ret = merit_fischer(xnew,ynew,znew,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,mu,gdiag,%
335 PSI_E,PSI_I);
336
337
338 function res = merit_fischer(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,mu,gdiag,%
339 PSI_E,PSI_I)
340
341 [fin, feq] = const_quad(x,Gin,hin,rin,A,b,Aeq,beq,gdiag);
342 h_ma = f_comp(fin, y, mu, 'frod');
343
344 res = norm([LagClas quad(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,grad');...
345 h_mu; feq], Inf);
346
347
348
349 function [dx, dy, dz, prec] = solversystem(LXX,LX,fin,feq,Jin,Jeq,y,r,mu, PSI_I)
350
351 % rieši system [X, -A', B'; D1*A, D2, 0; B 0 0] = [-C; -D; -E]
352
353 [h_mu, Da, Db] = f_comp(fin,y,mu,'all');
354
355 n = length(LX);
356 m = length(h_mu);
357 meq = length(fe);
358
359 LXX.Fischer_system = [LXX, -Jin', Jeq]; diag(Da)*Jin, diag(Db), zeros(m, meq);
360 Fischer_system = [LXX, -Jin', Jeq]; diag(Da)*Jin, diag(Db), zeros(m, meq);
361 Fischer_rhs = zeros(meq, m+meq);
362 Fischer_rhs = [-Lx; h_mu; fe];
363
364 s = Fischer_system \ Fischer_rhs;
365 prec = norm(Fischer_system\ Fischer_rhs);
366
367 dx = s(1:n);
368 dy = s(n+1:n+m);
369 dz = s(n+m+1:n+m+meq);

```

Zoznam pomocných funkcií: funkcie na spracovanie voliteľných parametrov ako vstupov do predošlých hlavných funkcií, funkcie na výpočet Lagrangeových funkcií, ψ a merit funkcií, funkcia algoritmu GMW81 a výhľadávania na lúci.

Pomocné procedúry pre hlavné funkcie.

```

1 function roptions = setoptions(index)
2 % funkcia sluzi na spracovanie voliteľného vstupu do testovacích
3 % funkcií ULDRU3PHR, FISCHER, FISCHER2, POLYAK, POLYAK2
4 % funkcia ULDRU3PHR, FISCHER, FISCHER2, POLYAK, POLYAK2
5 % uprava vstupu
6 % n = numel(index);
7 n = numel(index); % ak maju nacitané polia rôzne rozmeru, prebytočne udaje ignorujeme
8 input = reshape(index, 1, n);
9 if n == 1
10    % na vstupu je jeden parameter, musí byť STRUCT
11    if instruc(input{1})
12       options = input{1};
13    else
14       error('Poľe parametrov OPTIONS musí byť typu struct');
15    end
16   end
17 else
18    % vstup je organizovaný ako sied dvojíc, kde prvý prvek je nazov
19    % parametrov (alebo poľa parametrov) a druhý prvek užava jeho (ich)
20    % hodnotu. V prípade, že je parametrov alebo hodnoty rôzny pocet,
21    % prebytočne sa ignoruje
22    if mod(n, 2) == 1
23       warning('SetOptions:nSize', 'Rôzne rozmeru vstupných polí, prebytočne ignorujem');
24       input(n) = [];
25    end
26    for i=1:n/2
27       % nacítame nazov parametra a jeho hodnotu
28       if iscell(input(2*i-1))
29          proc = input(2*i-1);
30       else
31          proc = input(2*i-1);
32       end
33       if iscell(input(2*i))
34          val = input(2*i);
35       else
36          val = input(2*i);
37       end
38       NumOfVals = length(val); % pocet objektov v bunke val
39       NumOfProc = length(proc); % pocet objektov v bunke proc
40
41       % Poľia PROC a VAL zredukujeme preskupením udajov
42       val = reshape(val, 1, NumOfVals);
43       try
44          proc = reshape(strtrin(proc), 1, NumOfProc);
45       catch err
46          if strcmp(err.identifier, 'MATLAB:strtrim:InputClass')
47             error('Názvy parametrov musia byť typu string');
48          else
49             retrhow(err);
50          end
51       end
52    end
53
54    % ak maju nacitané polia rôzne rozmeru, prebytočne udaje ignorujeme
55    if NumOfVals ~= NumOfProc
56       warning('SetOptions:nSize', 'Rôzne rozmeru nazov parametrov', ...
57               ', a ich hodnot, prebytočne ignorujem');
58    end
59
60    % predjeme všetky prvky polí PROC a VAL a vytvoríme struktúru k
61    % dalšiemu spracovaniu
62    for j = 1:min(NumOfVals, NumOfProc)
63       tproc = proc{j}; tval = val{j};
64       if iscell(tproc) || iscell(tval)
65          error('Príliš mnoho vnorených objektov typu cell');
66       end
67
68       % vytvoríme príkaz v strukture roptions s nazvom tproc a
69       % hodnotou tval
70       roptions.(proc{j}) = val{j};
71    end
72
73 end
74
75 function hod = setting(opts, name, def)
76
77 % funkcia na ziskanie nastavení zo struktury OPTS. NAME je identifikátor
78 % parametrov, ktorý hľadame, a DEF je jeho defaultná hodnota (struktúra
79 % DEF máis obsahovať pole NAME).
80
81 if ~isfield(def, name)
82    error('Struktúra DEF neobsahuje pole NAME');
83 end
84 if isempty(opts)
85    hod = def.(name);
86    return;
87 end
88
89 % najdene zadanu hodnotu parametra
90 NameInStr = fieldnames(opts); % vsetky možne uvažované polia
91 NumberOfEntries = length(NameInStr);
92 for i=1:NumberOfEntries
93    NameToCmp = NameInStr(i);
94    ind = find(strcmp(NameToCmp, name, length(NameToCmp)));
95    if isempty(ind)
96       ind = 1;
97    end
98    break;
99 end
100
101 % ak sme ju nasiť, vymenime hodnotu z pola OPTS
102 if isempty(ind)
103    hod = def.(name);
104 else
105    hod = opts.(NameToCmp);
106 end

```

Funkcie na výpočet klasickej a rozšírenej Lagrangeovej funkcie, a funkcia na výpočet ohriadení a ich Jakobiánov (funkcie pre balík CUTER sú analogické).

```

1 function varargout = const_quad(x,Gin,hin,rin,A,b,Aeq,beq,gdiag)
2   % [fin, feq, Jin, Jeq] = const_quad(x,Gin,hin,rin,A,b,Aeq,beq,gdiag)
3   % funkcia pocita funkne hodnoty a Jakobiensy ohaniceni.
4   % pocet vystupnych parametrov> 1-4.
5   % funkcia pocita funkne hodnoty a Jakobiensy ohaniceni.
6   % pocet vystupnych parametrov> 1-4.
7   %
8   % fin - funkna hodnota ohaniceni v tvare nerovnosti
9   % feq - funkna hodnota ohaniceni v tvare rovnosti
10  % Jin - Jacobian ohaniceni v tvare nerovnosti
11  % Jeq - Jacobian ohaniceni v tvare nerovnosti
12
13 if nargin < 9
14   gdiag = [];
15   if nargin < 8
16     error('Funkcia const_quad potrebuje 8 vstupnych argumentov');
17   end
18 end
19
20 % rozmerov prislusnych matic
21 sz_n = length(x);
22 sz_mq = length(rin);
23 sz_m = sz_mq + size(A, 1);
24
25 % kontrola rozmerov matice Gin
26 if isempty(gdiag)
27   sz_g = size(Gin, 2);
28   if sz_g == sz_mq
29     gdiag = 1;
30   elseif sz_g == sz_mq * sz_n
31     gdiag = 0;
32   else
33     error('Matrica Gin nema pozadovane rozmer');
34   end
35 end
36
37 fin = zeros(sz_m, 1);
38 if nargin < 3
39   % vypocet kvadratickych ohaniceni
40   if gdiag == 1
41     for i=1:sz_mq
42       fin(i) = x.*((0.5*Gin(:, i).*x + hin(:, i)) - rin(i));
43     end
44   else
45     for i=1:sz_mq
46       fin(i) = x.*((0.5*Gin(:, sz_n*(i-1)+1:sz_n*i).*x + hin(:, i)) - rin(i));
47     end
48   end
49
50   % priradenie linearnych ohaniceni
51   fin(sz_m+1:sz_m) = A*x-ri;
52   feq = A*qxx-beq;
53
54   % priradenie vystupu
55   varargout{1} = fin;
56   varargout{2} = feq;
57   else
58   % vypocet kvadratickych ohaniceni
59   Jin = zeros(sz_m, sz_n);
60   if gdiag == 1
61     for i=1:sz_mq
62       temp = Gin(:, i).*xi;
63       fin(i) = x.*((0.5*temp + hin(:, i)) - rin(i));
64     end
65   else
66     for i=1:sz_mq
67       if length(D) ~ = sz_n && ~isempty(D)

```

```

48 elseif max(length(b), size(A,1)) ~= length(y) - sz_mq
49   error('Vektor b alebo matica A maju nespravy rozmer');
50 elseif max(length(beg), size(Aed,1)) ~= sz_meq
51   error('Vektor beg alebo matica Aeq maju nespravy rozmer');
52 elseif max(length(G), length(h)) ~= sz_n
53   error('Vektor h alebo matica G maju nespravy rozmer');
54 end
55 %
56 % kontrola a identifikacia zadania matice Gin
57 sz_g = size(Gin, 2);
58 if sz_g == sz_mq
59   gdiag = 1;
60 elseif sz_g == sz_n * sz_mq
61   gdiag = 0;
62 else
63   error('Matica Gin ma nespravy rozmer');
64 end
65 %
66 % výkonanie pozadovaných výpočtov
67 if typ == 1
68   '% počita sa funkcia hodnota Lagrangeovej funkcie
69   [fin, feq] = const_quad(x,Gin,hin,rin,A,b,Aeq,beg,gdiag);
70   res = x'*0.5*x + h + feq*xz - fin*y;
71   if (~isempty(D))
72     res = res + 0.25*(x'*0.*x)^2;
73   end
74   '% prípravenie
75   varargout[1] = res;
76   varargout[2] = res;
77   typ == 2
78 elseif typ == 3
79   '% počita sa gradient Lagrangeovej funkcie
80   [res, ' , Jin, Jeq] = const_quad(x,Gin,hin,rin,A,b,Aeq,beg,gdiag);
81   res = Gx + h + Jeq*x - Jin*y;
82   if (~isempty(D))
83     tmp = D*x;
84     res = res + (x'*tmp)*tmp;
85   end
86   '% prípravenie
87   varargout[1] = res;
88   varargout[2] = res;
89   varargout[3] = res;
90 elseif typ == 4
91   '% počita sa Hessova matica Lagrangeovej funkcie
92   sel = (1:sz_n+1:sz_n^2)';
93   res = G;
94   if (~isempty(D))
95     tmp = D*x;
96     res = res + 2*(tmp*tmp);
97     res(sel) = res(sel) + x'*tmp*D;
98   end
99   if gdiag == 1
100    for i=1:sz_mq
101      res(sel) = res(sel) - y(i)*Gin(:, i);
102    end
103  end
104  else
105    for i=1:sz_mq
106      res = res - y(i)*Gin(:, sz_n*(i-1)+1:sz_n*i);
107    end
108  end
109  '% prípravenie
110  varargout[1] = res;
111  varargout[2] = res;
112  elseif typ == 4
113    '% počita sa gradient a Hessova matica Lagrangeovej funkcie
114    %
115    %
116    %
117    %
118    %
119    %
120    %
121    if (~isempty(D))
122      tmp = D*x;
123      res1 = res1 + (x'*tmp)*tmp;
124      res2 = res2 + 2*(tmp*tmp);
125      res2(sel) = res2(sel) + x'*tmp*D;
126    end
127    if gdiag == 1
128      for i=1:sz_mq
129        res2(sel) = res2(sel) - y(i)*Gin(:, i);
130      end
131    else
132      for i=1:sz_mq
133        res2 = res2 - y(i)*Gin(:, sz_n*(i-1)+1:sz_n*i);
134      end
135    end
136    '% výstup sa zordene ako [grad, hess]
137    % prípravenie
138    varargout[1] = res1;
139    varargout[2] = res2;
140  else
141    '% počita sa funkcia hodnota a gradient Lagrangeovej funkcie,
142    % výstup sa zordene ako [fval, grad]
143    [fin, feq, Jin, Jeq] = const_quad(x,Gin,hin,rin,A,b,Aeq,beg,gdiag);
144    res1 = x'*(0.5*Gx + h) + feq*xz - fin*y;
145    res2 = Gx + h + Jeq*xz - Jin*y;
146    if (~isempty(D))
147      tmp = D*x;
148      res1 = res1 + 0.25*(x'*tmp)^2;
149      res2 = res2 + (x'*tmp)*tmp;
150    end
151    '% prípravenie
152    varargout[1] = res1;
153    varargout[2] = res2;
154  end
155 end
1
2 function varargout = LAGRAGU_QUAD(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beg,r,...)
3 %
4 % funkcia počita funkciu hodnotu, gradient alebo Hessovu maticu
5 % rozšírenú Lagrangeové funkcie definovanéj ako
6 %  $L_A(x,y,z) = f(x) + 1/r \sum (psi_1(r*g(x), y, \dots) + \dots$ 
7 %  $\dots + 1/r \sum (psi_8(r*h(x), z, \dots))$ .
8 % navrátove hodnoty zavisia od hodnoty premennej met, ktoru moze byt
9 % FVAL - počita sa funkcia hodnota Lagrangeovej funkcie
10 % GRAD - počita sa Gradient Lagrangeovej funkcie
11 % HESS - počita sa Hessova matica Lagrangeovej funkcie
12 % GRADHES - počita sa gradient a Hessova matica Lagrangeovej funkcie
13 % FVALGRAD - počita sa funkcia hodnota a gradient Lagrangeovej funkcie
14 %
15 % PSI je string a určuje nazov penalizacej funkcie, ktorá je
16 % priradená k rozšíreniu Lagrangeovej funkcie. PSI_I zodpoveda pen.
17 % neronvic a PSI_E patrí pen. funkcií rovníc. Oba funkcie musia mať 3
18 % vstupné parametre.
19 %
20 if nargin < 17
21   error('Funkcia LAGRAGU_QUAD potrebuje 17 vstupných argumentov');
22 end
23 %
24 % kontrola vstupnej premennej met

```

```

25 switch lower(net)
26   case 'fhod'
27     typ = 1;
28   case 'grad'
29     typ = 2;
30   case 'hess'
31     typ = 3;
32   case 'gradhes'
33     typ = 4;
34   case 'fhodgrad'
35     typ = 5;
36   otherwise
37     error('Net musi byt FHOD, GRAD, HESS, FHODGRAD, alebo GRADHESSE');
38 end
39 % kontrola vystupnych parametrov
40 if typ < 4 && nargout > 1
41 error('Prilis vela vystupnych argumentov');
42 error('Prilis vela vystupnych argumentov');
43 elseif typ >= 4 && nargout > 2
44 error('Prilis vela vystupnych argumentov');
45 end
46 % prilisne rozmer ulohy
47 % prilisne rozmer ulohy
48 sz_n = length(x);
49 sz_xeq = max(size(hn, 2), length(rin));
50 sz_dqg = max(size(hn, 2), length(rin));
51
52 % kontrola rozmerov
53 if length(D) == sz_n && ~isempty(D)
54   error('Diagonala matice D ma nespravny rozmer');
55 elseif max(length(b), size(A, 1)) == length(y) - sz_mq
56 error('Vektor b alebo matrica A maju nespravny rozmer');
57 elseif max(length(beg), size(Aeg, 1)) == sz_mq
58 error('Vektor beg alebo matrica Aeg maju nespravny rozmer');
59 elseif max(length(G), length(h)) == sz_n
60 error('Vektor h alebo matrica G maju nespravny rozmer');
61 end
62 %
63 % kontrola a identifikacia zadania matice Gin
64 sz_g = size(Gin, 2);
65 if sz_g == sz_mq
66   gdag = 1;
67 elseif sz_g == sz_n * sz_mq
68   gdag = 0;
69 else
70   error('Matrica Gin ma nespravny rozmer');
71 end
72 %
73 % výkonanie pozadovaných výpočtov
74 if typ == 1
75   % počita sa funkcia hodnota a gradient Lagrangeovej funkcie
76   [fbar, feq] = const_quad(x, Gin, hin, rin, A, b, Aeq, beq, gdiag);
77   res = x.* (0.5*x*x + h) + (sum(feval(psi_I, rfin, y, 'der1')) +
78   sum(feval(psi_E, rfeq, z, 'der1'))) / r;
79   if (~isempty(D))
80     res = res + 0.25*(x.*0.*x)^2;
81   end
82   % priradenie
83   varargout{1} = res;
84   varargout{2} = res;
85   elseif typ == 2
86     % počita sa gradient Lagrangeovej funkcie
87     [fbar, feq] = const_quad(x, Gin, hin, rin, A, b, Aeq, beq, gdiag);
88     ybar = - feval(psi_I, rfin, y, 'der1');
89     zbar = feval(psi_E, rfeq, z, 'der1');
90   res = LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
91   res - LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
92   r * (Jin.* (ones(sz_n,1)*feval(psi_I, rfin, y, 'der2'))*Jin +
93   res - LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
94   res - LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
95   % priradenie
96   varargout{1} = res;
97 elseif typ == 3
98   % počita sa Hessova matrica Lagrangeovej funkcie
99   [fbar, feq, Jin, Jeq] = const_quad(x, Gin, hin, rin, A, b, Aeq, beq, gdiag);
100  ybar = - feval(psi_I, rfin, y, 'der1');
101  zbar = feval(psi_E, rfeq, z, 'der1');
102  res = LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
103  r * (Jin.* (ones(sz_n,1)*feval(psi_I, rfin, y, 'der2'))*Jin +
104  res - LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
105  res - LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'hess') +
106  % priradenie
107  varargout{1} = res;
108  elseif typ == 4
109  % počita sa gradient a Hessova matrica Lagrangeovej funkcie,
110  % vo výstupe su zoradené ako [grad, hess]
111  [fbar, feq, Jin, Jeq] = const_quad(x, Gin, hin, rin, A, b, Aeq, beq, gdiag);
112  ybar = - feval(psi_I, rfin, y, 'der1');
113  zbar = feval(psi_E, rfeq, z, 'der1');
114  res1 = x.* (0.5*x*x + h) + 1/(* (sum(feval(psi_I, rfin, y, 'fdod')) +
115  res2 = LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'grad') +
116  res1, res2) = LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'grad') +
117  res2 + ...
118  r * (Jin.* (ones(sz_n,1)*feval(psi_I, rfin, y, 'der2'))*Jin +
119  res2 - res2 + ...
120  r * (Jin.* (ones(sz_n,1)*feval(psi_I, rfin, y, 'der2'))*Jin +
121  res1, res2 = x.* (0.5*x*x + h) + 1/(* (sum(feval(psi_I, rfin, y, 'fdod')) +
122  % priradenie
123  varargout{1} = res;
124  varargout{2} = res2;
125  % priradenie
126 else
127   % počita sa funkcia hodnota a gradient Lagrangeovej funkcie,
128   % vo výstupe su zoradené ako [grad, grad]
129   [fbar, feq] = const_quad(x, Gin, hin, rin, A, b, Aeq, beq, gdiag);
130   res1 = x.* (0.5*x*x + h) + 1/(* (sum(feval(psi_I, rfin, y, 'fdod')) +
131   if (~isempty(D))
132     res1 = res1 + 0.25*(x.* (D.*x))^2;
133   end
134   res1 = res1 + 0.25*(x.* (D.*x))^2;
135   ybar = - feval(psi_I, rfin, y, 'der1');
136   zbar = feval(psi_E, rfeq, z, 'der1');
137   res2 = LagrClas_quad(x,ybar,zbar,D,G,h,Gin,hin,rin,A,b,Aeq,beq,'grad');
138   % priradenie
139   varargout{1} = res1;
140   varargout{2} = res2;
141
142 end

```

Transformačné funkcie (Rockafellarova, Powell-Hestenesova a hyperbolická ψ funkcia, označené psi_I_PHR , psi_E , psi_I_hyp). Pred použitím je nutné skomplívať.

```

1 /* Pocita funkciu hodnotu, prvu a druhe derivacie Rockafellarovej
2 penalizacnej funkcie
3
4 PSI(xi, nu) = 0.5*[ max(0, nu-xi)^2 - nu*2 ]
5
6 IAG(x,y,...) = f(x) + 1/r*max(PSI(r*g(x),y)) + ...
7
8 #if !defined(MAX2)
9 #define MAX2(A, B) ((A) < (B) ? (B) : (A))
10 #endif
11
12 #include "mex.h"
13 #include <string.h>
14 #include <math.h>
15
16 /* vstupne argumenty musia byt v tomto poradi:
17 prhs[0] = vektor xi, double (n x 1), vektor hodnot ohraniceni
18 prhs[1] = vektor nu, double (n x 1), vektor mnozistvitorov
19 prhs[2] = retezec 'typ', udava, co sa ma vyzkonať
20 vystupom je vektor
21 */
22 void mexFunction(int nlhs,mxArray *phs[],int nrhs,const mxArray *prhs[])
23 {
24     /* inicializacie premennych/
25     mexErrMsgTxt("Funkcia potrebuje 3 vstupne parametre");
26     double *res, *xi, *nu;
27     char *type;
28     mwsize typelen;
29     mwindex len, i, typ;
30
31     /*vstupne kontroly*/
32     if (nrhs != 3) {
33         mexErrMsgTxt("Vstupna premenna xi musi byt string");
34     }
35     if (nlhs > 1) {
36         mexErrMsgTxt("Prilis vela vystupnych parametrov");
37     }
38     if ( !mxIsChar(prhs[2]) || (mxGetM(prhs[2]) != 1) ) {
39         mexErrMsgTxt("Vstupna premenna xi musi byt string");
40     }
41     if (mxGetM(prhs[0]) != 1 && mxGetN(prhs[0]) != 1) {
42         mexErrMsgTxt("Vstupna premenna xi musi byt vektor");
43     }
44     if (mxGetH(prhs[1]) != 1 && mxGetM(prhs[1]) != 1) {
45         mexErrMsgTxt("Vstupna premenna nu musi byt vektor");
46     }
47
48     /*kopirvanie retazca zo vstupnej premennej 'typ'*/
49     typeLen = mxGetM(prhs[2])*sizeof(mxChar) + 1;
50     type = mxalloc(typeLen);
51     if (mxGetString(prhs[2], type, typeLen) {
52         mexErrMsgTxt("Vektor xi a mu vytvarej dziky");
53     }
54
55     /*inicjalizacia smernikov*/
56     len = (mwIndex)MAX2(mxGetM(prhs[0]),mxGetN(prhs[0])) + 1;
57     if (len != (mwIndex)MAX2(mxGetM(prhs[1]),mxGetN(prhs[1]))) {
58         mexErrMsgTxt("Vektor xi a mu vytvarej dziky");
59     }
60     if ( mxIsEmpty(prhs[0]) || mxIsEmpty(prhs[1]) ) {
61         len = 0;
62     }
63
64     /*kontrola typu operacie*/
65     if (strcmp(type, "fodr") == 0) {
66         typ = 1;
67     } else if (strcmp(type, "der1_xi") == 0 || strcmp(type, "der1") == 0) {

```

```

135     }
136   }
137   /* pocita sa druha derivacia penalizacej casti
138   Rockefellarovej funkcie, Podla mu,nu*/
139   for ( i=0; i<len; i++ ) {
140     if (xi[i] <= nu[i] ) {
141       res[i] = 0;
142     } else {
143       res[i] = -1;
144     }
145   }
146 }
147 */
148 mxFree(type);
149 }

1 /* Pocita funkcmu hodnotu, prvu a druhe derivacie Hestenesovej
2 penalizacej funkcie. */
3
4 PSI(xi, mu) = xi*nu + 0.5*xi*xi
5 LAG(x, ..., z) = f(x) + ... + 1/r*sum(PSI(x*h(x),z)) + ...
6 */
7 #if !defined(MAX2)
8 #define MAX2(A, B) ((A) < (B) ? (B) : (A))
9 #endif
10

11 #include "mex.h"
12 #include <string.h>
13 #include <math.h>
14 /*
15 * vstupne argumenty musia byt v tomto poradi:
16 * prhs[0] = vektor xi, double (n x 1), vektor hodnot ohraniceni
17 * prhs[1] = vektor nu, double (n x 1), vektor mnozilipatorov
18 * prhs[2] = reazec 'typ', udava, co sa ma vykonat
19 * vystupom je vektor
20 */
22 void mexFunction(int nlhs,mxArray *phs[],int nrhs,const mxArray *prhs[])
23 {
24   /* inicializacie premennych*/
25   double *res, *xi, *nu;
26   char *type;
27   msSize typeLen;
28   mwIndex len, i, typ;
29
30   /*vstupne kontroly*/
31   if (nrhs != 3) {
32     mexErrMsgTxt("Funkcia potrebuje 3 vstupne parametre");
33   }
34   if (nlhs > 1) {
35     mexErrMsgTxt("Prilis vela vystupnych parametrov");
36   }
37   if ( !mxIsChar(prhs[2]) || (!mxGetM(prhs[2]) == 1) ) {
38     mexErrMsgTxt("Vstupny argument typ musi byt string");
39   }
40   if (mxGetM(prhs[0]) != 1 && mxGetM(prhs[0]) != 1) {
41     mexErrMsgTxt("Vstupna premenna xi musi byt vektor");
42   }
43   if (mxGetM(prhs[1]) != 1 && mxGetM(prhs[1]) != 1) {
44     mexErrMsgTxt("Vstupna premenna nu musi byt vektor");
45   }
46
47   /*kopirovanie retazca zo vstupnej premennej 'typ'*/
48   typeLen = mxGetN(prhs[2])*sizeof(mxChar) + 1;
49   type = mxMalloc(typeLen);
50   if (mxGetString(prhs[2], type, typeLen) {
51     mexErrMsgTxt("Chyba pri konverzii premennej typ");
52   }
53   /*inicjalizacia smernikov*/
54   len = (mwIndex)MAX(mxGetM(prhs[0]),mxGetM(prhs[1]));
55   if (len == (mwIndex)MAX2(mxGetM(prhs[1]),mxGetM(prhs[1]))) {
56     mexErrMsgTxt("Vektoru xi a nu musia byt rovnakej dlzky");
57   }
58   if ( mxIsEmpty(prhs[0]) || mxIsEmpty(prhs[1]) ) {
59     len = 0;
60   }
61 }

62 /*kontrola typu operacie*/
63 if (strcmp(type, "fthod") == 0) {
64   if (strcmp(type, "der1") == 0) {
65     typ = 1;
66   } else if (strcmp(type, "der2") == 0) {
67     typ = 2;
68   } else if (strcmp(type, "der2v") == 0) {
69     typ = 3;
70   } else {
71     mexErrMsgTxt("Chyba zadany typ operacie");
72   }
73 /*definovanie smernikov*/
74 phs[0] = mxCreateDoubleMatrix(len, 1, mxREAL);
75 res = mxGetPr(phs[0]);
76 for (i=0; i<len; i++) {
77   res[i] = mxGetPr(prhs[0]);
78   mu = mxGetPr(prhs[1]);
79 }

80 if (typ == 1) {
81   /* pocita sa funkcia hodnota penalizacnej casti
82   Hestenesovej funkcie */
83   for (i=0; i<len; i++) {
84     res[i] = (0.5*xi[i] + nu[i])*xi[i];
85   }
86   /* pocita sa prva derivacia penalizacnej casti
87   Hestenesovej funkcie, podla xi*/
88   for (i=0; i<len; i++) {
89     res[i] = xi[i] + mu[i];
90   }
91   /* pocita sa druha derivacia penalizacnej casti
92   Hestenesovej funkcie, podla xi,xi*/
93   for (i=0; i<len; i++) {
94     res[i] = xi[i] + mu[i];
95   }
96   res[i] = 1;
97 }
98
99 mxFree(type);
100 }

1 /* Pocita funknu hodnotu, prvu a druhe derivacie hyperbolickej
2 penalizacej funkcie. */
3
4 PSI(xi, nu) = ...;
5 LAG(x,y,...) = f(x) + 1/r*sum(PSI(r*x,g(x),y)) + ...
6
7 #if !defined(MAX2)
8 #define MAX2(A, B) ((A) < (B) ? (B) : (A))
9#endif
10
11 #include "mex.h"
12 #include <string.h>
13 #include <math.h>
14
15 /* vstupne argumenty musia byt v tomto poradi:
```

```

16 prhs[0] = vektor xi, double (n x 1), vektor hodnot obranieni
17 prhs[1] = vektor nu, double (n x 1), vektor multiplikatorov
18 prhs[2] = reťazec "typ", udava, co sa ma vykonať
19 vystupom je vektor
20 */
21 void mexFunction(int nlhs,mxArray *phls[],int nrhs,const mxArray *prhs[])
22 {
23 /* inicializacie premennych*/
24 double *res, *xi, *nu;
25 char *type;
26 mxArray *type;
27 mxArray len, i, typ;
28 mwIndex len;
29
30 /*vstupne kontroly*/
31 if (nrhs != 3) {
32 mexErrMsgTxt("Funkcia potrebuje 3 vstupne parametre");
33 }
34 if (nlhs > 1) {
35 mexErrMsgTxt("Prilis vela vystupnych parametrov");
36 }
37 if ( !mxIsChar(prhs[2]) || (mxGetM(prhs[2]) != 1) ) {
38 mexErrMsgTxt("Vstupny argument typ musi byt string");
39 }
40 if (mxGetM(prhs[0]) != 1 && mxGetM(prhs[0]) != 1) {
41 mexErrMsgTxt("Vstupna premenna xi musi byt vektor");
42 if (mxGetN(prhs[1]) != 1 && mxGetN(prhs[1]) != 1) {
43 mexErrMsgTxt("Vstupna premenna nu musi byt vektor");
44 }
45 }
46 /*kopirovanie retace zo vstupnej premennej *typ*/
47 /*kopirovanie retace zo vstupnej premennej *typ*/
48 typeLen = mxGetN(prhs[2])*sizeof(mxChar) + 1;
49 type = mxalloc(typeLen);
50 if (mxGetString(prhs[2], type, typeLen) != 0) {
51 mexErrMsgTxt("Chyba pri konverzii premennej typ");
52 }
53 /*inicIALIZacia smernikov*/
54 /*inicIALIZacia smernikov*/
55 len = (mwIndex)MAX2(mxGetM(prhs[0]),mxGetN(prhs[0]));
56 if (len != (mwIndex)MAX2(mxGetM(prhs[1]),mxGetN(prhs[1]))) {
57 mexErrMsgTxt("Vektor xi a mu musia byt rovnakej dĺžky");
58 }
59 if ( mxIsEmpty(prhs[0]) || mxIsEmpty(prhs[1]) ) {
60 len = 0;
61 }
62 /*kontrola typu operacie*/
63 if (strcmp(type, "thod") == 0) {
64
112
65 typ = 1;
66 } else if (strcmp(type, "der1") == 0) {
67 typ = 2;
68 } else if (strcmp(type, "der2") == 0) {
69 typ = 3;
70 } else {
71 mexErrMsgTxt("Chyba zadany typ operacie");
72 }
73 /*definovanie smernikov*/
74 /* pocita sa funkcia hodnota penalizacnej casti
75 phls[0] = mxCreateDoubleMatrix(len, 1, mxREAL);
76 res = mxGetPr(phls[0]);
77 xi = mxGetPr(prhs[0]);
78 nu = mxGetPr(prhs[1]);
79
80 if (typ == 1) {
81 /* pocita sa druhá derivacia penalizacnej casti
82 hyperbolicej funkcie */
83 for (i=0; i<len; i++) {
84 if (xi[i] == 0.0) {
85 res[i] = nu[i] * ( xi[i] - 1 ) *xi[i];
86 } else {
87 res[i] = nu[i] * ( 1/(1 + xi[i]) - 1 );
88 }
89 }
90 /* pocita sa druhá derivacia penalizacnej casti
91 hyperbolicej funkcie, podla xi*/
92 for (i=0; i<len; i++) {
93 if (xi[i] == 0.0) {
94 res[i] = nu[i] * ( 2*xi[i] - 1 );
95 } else {
96 res[i] = nu[i] * ( -1/pow(1+xi[i], 2) );
97 }
98 }
99 }
100 }
101 /* pocita sa druhá derivacia penalizacnej casti
102 hyperbolicej funkcie, podla xi, xi*/
103 for (i=0; i<len; i++) {
104 if (xi[i] == 0.0) {
105 res[i] = nu[i] * ( 2 );
106 } else {
107 res[i] = nu[i] * ( 2/pow(1+xi[i], 3) );
108 }
109 }
110
111 mxFree(type);
112

```

112

Subprocedúra Newtonovej metódy: funkcia cholsolve hľadá riešenie systému rovnic $(\nabla^2 F(\mathbf{x}) + \mathbf{E}) = -\nabla F(\mathbf{x})$ použitím modifikovaného Choleskeho rozkladu podľa algoritmu GMW81 [17], matica \mathbf{E} sa určí „za behu“. Nutné skompliovať.

```

1 /* Modifikovaná Newtonova metoda pre riesenie minimalizačného problemu,
2 Cholsolve je funkcia na hľadanie spadovo smeru s kriesením sustavy
3 Hess(L(x))rs = -grad(L(x)), kde sa použije modifikovaný Choleskeho
4 rozklad Hesovej matice podľa algoritmu GMW81 s diagonálnou
5 pivotizáciou, ktorý slúži na hľadanie smeru d x ako smeru "negative
6 curvature", ktorý je nulový, ak je matica hess(L(x)) dostatočne kladne
7 definitná, a nemulový v opačnom prípade. Pre tieto smery platia
8 nasledovne vztahy:

```

```

9 s *grad(L(x)) < 0, d *grad(L(x)) < 0, d *hess(L(x)) *d < 0.
10
11 Vstupne argumenty:
12
13 phs[0] : Hesova matica sustavy
14 phs[1] : Gradient sustavy
15 phs[2] : minimálny prirok, ktorý je v prípade nutnosti pripocitaný
16 k diagonale Hesovej matice

```

```

17   vystupne argumenty:
18   phs[0] : spadovy smer 's',
19   phs[1] : smer 'negative curvature' ,d'
20  */
21 /* definicie pre maximum z dvoch, resp. troch argumentov */
23 #if !defined(MAX2)
24 #define MAX2(A, B) ((A) < (B)) ? (B) : (A)
25 #endif
26 #if !defined(MAX3)
27 #define MAX3(A, B, C) (((A) < (B)) ? ((B) < (C)) ? (C) : (A) < (C) ? (C) : (A))
28 #endif
29 #endif
30 #if !defined(WIN32)
31 #define dmrm2 dmrm_2
32 #define ddot ddot_
33 #define idamax idamax_
34 #endif
35
36 #include "mex.h"
37 #include "blas.h"
38 #include <math.h>
39 #include <float.h>
40
41 void mexFunction(int nlhs, mxArray *plhs[], int nrhs, const mxArray *prhs[]) {
42
43   mwIndex n, i, j, k, q, lnd, *perm, one;
44   double *C, *l, *A, *b, *, *d, **y, *D, **B;
45   double norm_g, norm_E, delta, temp, theta, temp_D;
46   double max_diagA, max_ofdiagA, temp;
47
48   /* pocet vstupnych argumentov */
49   if (nrhs < 2 || nrhs > 3) {
50     mexErrMsgTxt("Funkcia potrebuje 2-3 vstupne parametre");
51   }
52   if (nlhs > 2 ) {
53     mexErrMsgTxt("Prilis vela vystupnych argumentov");
54   }
55
56   /* kontrola vstupnych argumentov */
57   n = mxGetM(prhs[0]);
58   if ( mxGetM(prhs[0]) != n ) {
59     mexErrMsgTxt("Vstupna matrica musi byt stvorcova");
60   }
61   if ( mxGetM(prhs[1]) != n || mxGetM(prhs[1]) != 1 ) {
62     mexErrMsgTxt("Vektor g musi byt typu n x 1");
63   }
64   if (nrhs == 3) { /* zadany je aj minimálny korelcny parameter */
65     if (mxGetNumberOfElements(prhs[2]) != 1) {
66       mexErrMsgTxt("Parameter MU musi byt skalar");
67     } else {
68       minE = fabs(mxGetScalar(prhs[2]));
69     }
70   } else { /* parameter nie je zadany */
71     minE = 0;
72   }
73
74   /* inicializacia vstupnych parametrov a smernikov na vstupy,
75   deklaracia dynamickych poli */
76   plhs[0] = mxCreateDoubleMatrix(n, 1, mxREAL); /* smer 's' */
77   plhs[1] = mxGetPr(plhs[0]);
78
79   L = (double *)mxCalloc(n, sizeof(double)); /* cholickeho rozkladu L */
80   C = (double *)mxCalloc(n, sizeof(double)); /* pomocna matice C */
81   D = (double *)mxCalloc(n, sizeof(double)); /* diagonala matice D */
82   E = (double *)mxCalloc(n, sizeof(double)); /* diagonala matice E */
83   y = (double *)mxCalloc(n, sizeof(double)); /* pomocny vektor Y */
84
85   perm = (mwIndex *)mxAlloc(n, sizeof(mwIndex)); /* * vektor permutacie */
86   A = mxGetPr(prhs[0]); /* * zdrojova matice A, Hessian */
87   b = mxGetPr(prhs[1]); /* * zdrojovy vektor b, gradient */
88   one = 1; /* * jednotka */
89
90   /*memcpy(C, mxGetPr(prhs[0]), n*n*sizeof(double));
91   /* inicializacia diagonaly */
92   for (ci=0; ci<n; ci++) {
93     C[ci] = A[ci];
94   }
95
96   /* uvodna permutacia */
97   for (ci=0; ci<n; ci++) {
98     perm[ci] = i;
99   }
100
101 /* vypocet najvacseho diagonalneho prvku |A[jj]| */
102 k = n + 1;
103 ind = idamax(n, C, &k) - 1; /* index najvacseho prvku v abs. hodnote */
104 max_diagA = fabs(C[ci+ind]);
105
106 /* vypocet najvacseho minodiagonaleho prvku */
107 max_ofdiagA = 0;
108 for (j=0; j<n-1; j++) {
109   for (i=j+1; i<n; i++) {
110     temp = fabs(C[i*cn+i]);
111     if (temp > max_ofdiagA) {
112       max_ofdiagA = temp;
113     }
114   }
115   temp = max_ofdiagA;
116   max_ofdiagA = n > 1 ? max_ofdiagA/sqrt(n*n-1) : max_ofdiagA;
117
118 /* vypocet beta^2 */
119 betasq = MAX3(max_ofdiagA, max_diagA, DBL_EPSILON);
120
121 /* vypocet delta, ako MU, ak je na vstupe zadane, alebo ako
122  |H|*macheps, ak je MU nezadané */
123 temp = temp + max_diagA;
124 delta = MAX2(DBL_EPSILON * MAX2(temp, 1), minE);
125
126 /* vypocet normy gradientu */
127 norm_g = dnrm2(&b, b, &one); /* 2-norma vektora b */
128
129 /* Choleskeho rozklad matice A na dolnotrojuholnikovu matice L */
130 for (j=0; j<n; j++) {
131   for (i=j+1; i<n; i++) {
132     L[i*j+j] = 1; /* prechazanie po stpoch */
133   }
134
135   /* najdem najvacsiu diagonalnu hodnotu matice A */
136   temp = fabs(C[i*i+1]);
137   for (k=j+1; k<n; k++) {
138     if (temp < fabs(C[i*k+k])) {
139       temp = fabs(C[i*k+k]);
140     }
141   }
142
143   /* symetricka vymena riadkov a stlpcov matice C a A */
144   if (q != j) {
145     /* permutacia */
146     temp = perm[j];
147     perm[j] = perm[q];
148     perm[q] = temp;
149   }
150
151 /* vymena riadkov a stlpcov matice A a C */

```

```

151     for ( k=0; k<n; k++ ) {
152         temp = C[ikn+j];
153         C[ikn+j] = C[ikn+q];
154         C[ikn+q] = temp;
155     }
156     for ( k=0; k<n; k++ ) {
157         temp = C[ijk];
158         C[ijk] = C[qnk];
159         C[qnk] = temp;
160     }
161 }
162 /* vypocet dodatocnych premennych C_ij */
163 for ( i=0; i<n; i++ ) {
164     L[i*n+j] = C[i*rn+j]/D[i];
165 }
166
167 for ( i=i+1; i<n; i++ ) {
168     temp = C[i*n+r];
169     for ( k=0; k<j; k++ ) {
170         temp = temp - L[k*rn+j]*C[k*n+r];
171     }
172     temp = temp - E[i];
173     C[j*n+i] = temp;
174 }
175 /* maximum z hodnot |c(i,j)| = |l(i,j)*d(j)|, i != j, i>j */
176
177 ind = n - j - 1;
178 if ( ind != 0 ) {
179     ind = idamax (&ind, &C[j*n+j+1], &one);
180     theta = fabs(C[j*n+j+ind]);
181 } else {
182     theta = 0;
183 }
184 /* modifikovana diagonala */
185 temp_D = MAX3(theta*theta/betasq, fabs(C[j*n+j]), delta);
186 D[j] = temp_D;
187 E[j] = temp_D - C[j*n+j];
188
189 /* uprava diagonaly prvkov */
190 for ( i=j+1; i<n; i++ ) {
191     temp = C[i*n+r];
192     C[i*n+r] = C[i*n+r] - temp*temp/temp_D;
193 }
194 /* MAIN LOOP */
195
196 /* inf-norm matice E */
197 ind = idamax (n, E, &one);
198 norm_E = E/ind-1;
199
200 /* **** spatne hladanie smeru pomocou rieseni trojuholnikyurch systemov */
201 /* **** spatne hladanie smeru pomocou rieseni trojuholnikyurch systemov */
202 /* **** spatne hladanie smeru pomocou rieseni trojuholnikyurch systemov */
203 /* **** spatne hladanie smeru pomocou rieseni trojuholnikyurch systemov */
204
205 /* hladanie spadoveho smeru s */
206 for ( i=0; i<n; i++ ) {
207     temp = b[perm[i]];
208     for ( k=0; k<i; k++ ) {
209         temp = temp + L[k*n+i]*y[k];
210     }
211     y[i] = -temp;
212 }
213 /* predelenie diagonalou */
214 for ( i=0; i<n; i++ ) {
215
216     y[i] = y[i] / D[i];
217
218     /* spatna substitucia */
219     for ( i=n-1; i>0; i-- ) {
220         temp = y[i];
221         for ( k=i+1; k<n; k++ ) {
222             temp = temp - L[i*n+k]*perm[k];
223         }
224         s[perm[i]] = temp;
225     }
226 }
227 /* hladanie 'direction of negative curvature' */
228 if ( nlhs > 1 ) {
229     /* pozadujeme aj tento vrstup */
230     phis[1] = mxCreateDoubleMatrix(n, 1, mxREAL); /* smer 'd' */
231
232     d = mxGetPr(phis[1]);
233
234     if ( normE != 0 ) {
235         ind = 0;
236         temp = D[0] - E[0];
237         for ( i=1; i<n; i++ ) {
238             if ( temp > D[i] - E[i] ) {
239                 temp = D[i] - E[i];
240                 ind = i;
241             }
242         }
243         /* riesime sustavu L'*L*x = e_j */
244         for ( i=n-1; i>ind; i-- ) {
245             d[perm[i]] = 0;
246         }
247         d[perm[ind]] = 1;
248         for ( i=ind-1; i>0; i-- ) {
249             temp = 0;
250             for ( k=i+1; k<ind; k++ ) {
251                 temp = ddot(&n, d, &one, b, &one);
252             }
253             if ( temp > 0 ) {
254                 for ( i=0; i<n; i++ ) {
255                     d[i] = -temp;
256                 }
257             }
258             if ( norm_E != 0 ) {
259                 temp = temp + L[i*n+k]*d[perm[k]];
260             }
261             for ( i=0; i<n; i++ ) {
262                 d[i] = -d[i];
263             }
264         }
265     }
266     /* else {
267         /* d = 0 */
268         for ( i=0; i<n; i++ ) {
269             d[i] = 0;
270         }
271     }
272
273     /* uvolnenie pamate */
274
275     mxFree(L);
276     mxFree(D);
277     mxFree(E);
278     mxFree(Y);
279
280 }

```

Vyhľadávanie na lúči: Brentov algoritmus na hľadanie koreňa funkcie $s^T \nabla F(\mathbf{x} + \lambda s)$, použitá implementácia je prepisom algoritmu *zero z* [6], s. 58-59, zdrojom bola takisto publikácia [37], a algoritmus More a Thuente [25], ktorý je založený na subfunkcii MCSRCH fortranovej funkcie LBFGS (obsiahnutá napr. v distribúcii MINPACK) od J. Nocedala, a na prepise tejto funkcie od D. O'Leary.

```

1 function alpha_t = brentzero(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,s, ...
2   PSL_E, PSL_I)
3   % hľadanie optimalnej dĺžky kroku Lambda, Brentova metoda na hľadanie
4   % koreňa gradientu funkcie Lagrange(x+t*lam,y).
5   % Ref: Numerical Recipes in C: The Art of Scientific Computing, 3rd
6   % edition, strany 454-456.
7   % najprv nasleduje pokus u zasklukovanie minima na intervale
8   I = [alpha_1, alpha_t]
9   alpha_min = 0.001;
10  epsilon = 1e-4;
11  EPSUTAL = eps;
12  Maxters = 20;
13
14  % najprv nasleduje pokus u zasklukovanie minima na intervale
15  L = [alpha_1, alpha_t]
16  alpha_max = 8;
17
18  alpha_l = 0;
19  alpha_t = 1;
20  gt = s.*LagAug_quad(x + s,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r, ...
21   PSL_E, PSL_I, grad);
22
23 while gt <= 0
24   alpha_l = alpha_t;
25   g1 = gt;
26   alpha_t = 2.5*alpha_t;
27   gt = s.*LagAug_quad(x + alpha_t*s,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r, ...
28   PSL_E, PSL_I, grad);
29 end
30
31 if alpha_l == 0
32   g1 = s.*LagAug_quad(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r, ...
33   PSL_E, PSL_I, grad);
34 end
35
36 gu = gt;
37 alpha_l = alpha_t;
38 e = alpha_t - alpha_1;
39 d = e;
40
41 for k=1:Maxters
42   % USPORIADANIE: alpha_t je najlepši odhad lambda, koren je uzavretý na
43   % intervalu medzi alpha_t a alpha_u, alpha_l je predosá hodnota
44   % alpha_t. Vymiká tvorivá prva iteráciu, kedy je alpha_u == alpha_t a
45   % alpha_l je opäcy koniec intervalu.
46
47   if (gt>0 && gu>0) || (gt<0 && gu<0)
48     alpha_u = alpha_1;
49     g1 = g1;
50     e = alpha_t - alpha_1;
51     d = e;
52
53   % zoradenie bodov
55   if abs(gu) < abs(gt)
56     alpha_l = alpha_t;
57     alpha_t = alpha_u;
58     alpha_u = alpha_l;
59     g1 = gt;
60     gt = gu;
61     gu = g1;
62
63   % nastavenie konečnej tolerancie ako súčet reálnejnej a absolútnej
64   % tolerancie
65   tol = 2*EPSUTAL*abs(alpha_t) + 0.5*epsilon;
66   m = 0.5*(alpha_u - alpha_t);
67
68   % kontrola výstupu
69   if (abs(m) <= tol) || gt == 0 )
70     break;
71   end
72
73
74   % Analýza možných bripadov v ktorých priadieme novu hodnotu kroku
75   % na zaklade bisekcie, lineárnej interpolacie alebo inverznej
76   % kvadratickej interpolacie z trojice dat [g1, gt, gu].
77   if (abs(e) < tol) || abs(g1) <= abs(gt) )
78     % Vykona sa bisekcia
79     e = m;
80     d = e;
81   else
82     S = gt/g1;
83     if alpha_l == alpha_u
84       % Vykona sa lineárna interpolacia
85     P = 2*m*S;
86     Q = 1 - S;
87   else
88     % Vykona sa inverzna kvadraticka interpolacia
89     Q = g1/gn;
90     R = gt/gn;
91     P = S*(2*m*Q*(Q-R) - (alpha_t-alpha_l)*(R-1));
92     Q = (S - 1)*(Q - 1)*(R - 1);
93   end
94   if P > 0
95     Q = -Q;
96   else
97     P = -P;
98   end
99   S = e;
100  e = d;
101
102  % podmienky na overenie vhodnosti interpolovaného bodu
103  if (2*P-3*m*Q - abs(tol)*Q) && P < abs(0.5*S*Q)
104    d = P/Q;
105    e = m;
106    d = e;
107
108  end
109
110

```

```

48 phass1 = 1;
49 [finit, ginit] = LagrHug-quadd(x,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,...;
50 PSI_E, PSI_I, 'fhodgrad');
51 info = 0;
52
53 % tolerancie, mu musi byt mensie ako eta !!!
54 mu = 1e-4; % tolerancia v prvej podmienke (P1)
55 eta = 0.9; % tolerancia v druhej podmienke (P2)
56 xtol = 1e-5; % tolerancia na sirku intervalu [a,min, a,max]
57
58 if mu > min(0.5, eta)
59 error('Chyba nastaenie parametrov MU a ETA. Ukoncujem funkciu MORETHUENTE');
60 end
61
62 % kontrola spadovosti smeru s
63 dheight = ginit.*s;
64 if (dheight >= 0.0)
65 error('Smer S nie je spadovy. Ukoncujem funkciu MORETHUENTE');
66 end
67
68 % pomocna hodnota jedneho z testovacich kriterii a sirkas intervalu I
69 gcrit = mu*ginit;
70 width = alpha_max - alpha_min;
71 widthl = 2*width;
72
73 % nastavime pociatocne hodnoty krokov alpha_l a alpha_u ako krajne hodnoty
74 % intervalu neuveritosti
75 alphal = 0;
76 alphau = finit;
77 f1 = dheight;
78 alphau = 0;
79 fu = finit;
80 gu = dheight;
81
82 while true
83 % minimally a maximally krok pre pocitanie vzhladom k sucasnemu intervalu
84 % neuveritosti I, krok alpha_t musi byt v pozadovanom rozmedzi.
85 if bracketed
86 a_min = min(alpha_l, alpha_u);
87 a_max = max(alpha_l, alpha_u);
88 else
89 a_min = alpha_l;
90 a_max = alpha_t + 4*(alpha_t - alpha_l);
91 end
92 alpha_t = min(max(alpha_t, alpha_min), alpha_max);
93
94 % vypocet funknej hodnoty a gradientu v smere pre novy bod x + alpha_t*s
95 [ft, grt] = LagrAng-quad(x+alpha_t*s,y,z,D,G,h,Gin,hin,rin,A,b,Aeq,beq,r,...;
96 PSI_E, PSI_I, 'fhodgrad');
97 fcrit = finit + alpha_t*gcrit;
98
99 %%%% VYKONAVANIE
100 % nie je mozne pokracovať v hľadaní kroku z dovođu zaokruhlovacich
101 % chyb, pristupny krok nemusí existovať
102 if ( bracketed && (alpha_t <= a_min || alpha_t >= a_max) )
103 info = 6;
104 end
105
106 % krok alpha_t dosiahol hornu pripustnu hranicu
107 if ( alpha_t == alpha_max && ft <= fcrit && gt <= gcrit )
108 info = 5;
109
110 % krok alpha_t dosiahol spodnu pripustnu hranicu
111 if ( alpha_t == alpha_min && (ft > fcrit || gt > gcrit) )
112 info = 4;
113 end
114 % minimum je obsiahnuté v intervale neurcitosti, ktorého relatívna
```

```

115 % sirkia je menouj ako xiol
116 if ( bracketed && a_max-a_min <= xtols*a_max )
117   info = 2;
118 end
119 % Poradovany krok alfa_t najdeny, (P1) aj (P2) splne
120 if ( ft < fcrit && abs(gt) < eta*(-cginit) )
121   info = 1;
122 end
123 % ukoncenie hľavnej iteracie
124 if (info == 0)
125   return
126 end
127
128 % urcenie fazy algoritmu, ktoru urcuje pouzitie pomocnej funkcie
129 % nie (aux urcuje pouzitie pomocnej funkcie)
130 % na odhadnutie nového kroku
131 if (phase1 && ft <= fct && gt >= min(mu,eta)*cginit)
132   phase1 = 0;
133
134 % zistime, či k urceniu nového kroku použijeme pomocnu funkciu alebo
135 % nie (aux urcuje pouzitie pomocnej funkcie)
136 if (phase1 && ft <= fl && ft > fcrit)
137   aux = 1;
138
139 ft = ft - alpha_t*cgrit;
140 fl = fl - alpha_l*cgrit;
141 fu = fu - alpha_u*cgrit;
142 gt = gt - gerit;
143 g1 = g1 - gerit;
144 gu = gu - gerit;
145 else
146   aux = 0;
147 end
148
149 % Nasleduje výpočet odhadu nového kroku na základe súčasných údajov.
150 % k dispozícii je aktuálny odhad kroku alfa_t, a krajne body intervalu
151 % alfa_l a alfa_t, v ktorom z nich máme užaj o funkciu hodnotu a
152 % derivaci. Body alfa_l a alfa_t su zordnené tak, že alfa_l > bod
153 % s nízkom funkčnou hodnotou (moze sa teda stat, že alfa_l > alfa_u).
154 % Ak je minimum ohranené bodmi alfa_l a alfa_u (bracketed = TRUE),
155 % potom alfa_t leži v tomto intervale. V každom prípade musí platiť,
156 % g1*(alpha_t-alpha_l) < 0, teda funkcia musí klestať v smere kroku alfa_l.
157 Z = g1 + gt - 3*(ft-fl)/(dalpha);
158 W = sqrt(Z*Z - gt*gt);
159 if dalpha > 0
160   temp = (W + Z - gt)/(2*W + gt - gt);
161   if ft > fl
162     bound = f;
163     dalpha = alfa_t - alfa_l;
164     Z = g1 + gt - 3*(ft-fl)/(dalpha);
165     W = sqrt(Z*Z - gt*gt);
166     if dalpha > 0
167       temp = (W + Z - gt)/(2*W + gt - gt);
168     else
169       temp = (W + gt - Z)/(2*W + gt - gt);
170     end
171   % odhadu pomocou kubickej a kvadratickej interpolacie
172   alpha_cub = alfa_l + dalphatemp;
173   alpha_quad = alfa_l + 0.5*dalphag1/( g1 - (ft-fl)/dalpha );
174   alpha_new = 0.5*(alpha_cub + alpha_quad);
175
176   % stanovenie nového odhadu kroku
177   if abs(alpha_cub - alfa_l) < abs(alpha_quad - alfa_l)
178     alpha_new = alpha_cub;
179   else
180     alpha_new = 0.5*(alpha_cub + alpha_quad);
181
182   % alpha_new leži v intervale I
183   bracketed = 1;
184
185   % B: plati ft < fl, a zaroven gradienty v bodoch alfa_l a alfa_t
186   % maju opacne znamenia. Opäť sa použije kvadraticka [g1, gt] a
187   % kubicka [fl, ft, g1, gt] interpolacia. Novy odhad lezi v intervale I
188   % (bracketed = TRUE).
189   elseif gt*gt < 0
190     bound = 0;
191     dalpha = alfa_t - alfa_l;
192     Z = g1 + gt - 3*(ft-fl)/dalpha;
193     W = sqrt(Z*Z - gt*gt);
194     if dalpha > 0
195       temp = (W + Z - gt)/(2*W + gt - gt);
196     else
197       temp = (W + gt - Z)/(2*W + gt - gt);
198     end
199   end
200   % odhadu pomocou kubickej a kvadratickej interpolacie
201   alpha_cub = alfa_l + dalphatemp;
202   alpha_quad = alfa_l - dalphag1/(gt - g1);
203
204   % stanovenie nového odhadu kroku
205   if abs(alpha_cub - alfa_t) >= abs(alpha_quad - alfa_t)
206     alpha_new = alpha_cub;
207   else
208     alpha_new = alpha_quad;
209   end
210
211   % alpha_new leži v intervale I
212
213   bracketed = 1;
214
215   % C: plati ft < fl, gt*gt >= 0 a |gt| < |g1|. Gradienty su rovnakeho
216   % znamenia a ich absoluta hodnota sa zmenzuje. Kubicky krok sa vezme
217   % do uvažu v prípade, ak kubicka interpolacia funkcia ide do nekonca
218   % v smere kroku, alebo ak je kubicky krok za krokom alfa_t. Pocita
219   % sa aj kvadraticky krok a v zavislosti od jeho polohy vzhľadom k
220   % alfa_l a od toho, ci je minimum obsiahnuť v intervale I, sa
221   % definuje nový odhad.
222   elseif abs(gt) < abs(g1)
223     bound = 1;
224     dalpha = alfa_t - alfa_l;
225     Z = g1 + gt - 3*(ft-fl)/dalpha;
226     W = sqrt(max(0, Z*Z - gt*gt));
227     if dalpha > 0
228       temp = (W + Z - gt)/(2*W + gt - gt);
229     else
230       temp = (W + gt - Z)/(2*W + gt - gt);
231     end
232
233   % ak kubicka interpolacia funkcia ide do nekonca v smere kroku,
234   % alebo kubicky krok leži za alfa_t, (v nasom prípade W > 0 a
235   % temp > 1, prípad W == 0 nastane, ak kubicka funkcia nejde do
236   % nekonca v smere kroku) prijme kubicky krok, inak
237   % ho nastavíme ako jeden z okrajov intervalu I.
238   if (temp > 1 || W == 0)
239     alpha_cub = alfa_l + dalphatemp;
240   elseif dalpha > 0
241     alpha_cub = a_max;
242   else
243     alpha_cub = a_min;
244   end
245   alpha_quad = alfa_l - dalphag1/(gt - g1);
246
247   % stanovenie nového odhadu kroku
248   if bracketed

```

```

249      if (abs(alpha_t-alpha_cub) < abs(alpha_t-alpha_quad))
250          alpha_new = alpha_cub;
251      else
252          alpha_new = alpha_quad;
253      end
254      if (abs(alpha_t-alpha_cub) > abs(alpha_t-alpha_quad))
255          alpha_new = alpha_cub;
256      else
257          alpha_new = alpha_quad;
258      end
259      if bracketed
260          if ft < f1, gt*gl >= 0, a|gt| >= |gl|, na urcenie minima pouzijeme
261          % kubicku interpolaciu bodov [ft, fu, gt, gu].
262          % ak alphat lezi v intervale I, novy krok urcime kubickou interpolaciou,
263          % inak ako novy krok zvolime jeden z krajnych bodov I
264          bound = 0;
265          if bracketed
266              alpha_u = alpha_u - alpha_t;
267              Z = gt + gu - 3*(fu-ft)/dalphi;
268              if dalphi > 0
269                  temp = (W + Z - gt)/(2*W + gu - gt);
270                  temp = (W + gt - Z)/(2*W + gt - gu);
271                  Z = gt + gu - 3*(fu-ft)/dalphi;
272                  W = sqrt(Z^2 - gn*gn);
273                  temp = (W + Z - gt)/(2*W + gu - gt);
274                  else
275                      temp = (W + gt - Z)/(2*W + gt - gu);
276                  end
277                  elseif alpha_t > alpha_u
278                      alpha_new = a_min;
279                  else
280                      alpha_new = a_min;
281                  end
282              end
283          end
284          % uprava intervalu I a preznamenie bodov intervalu
285          if f1 < ft
286              alpha_u = alpha_t;
287              gu = gt;
288              fu = ft;
289          end
290      else if gt*gl < 0
291          alpha.u = alpha_u;
292          fu = f1;
293          gn = gl;
294      end
295      alpha_u = alpha_t;
296      f1 = ft;
297      gl = gt;
298      end
299      % vypocet noveho kroku alpha_t
300      alpha_t = max(a_min, min(a_max, alpha_new));
301      if bracketed && bound
302          alpha_t = max(a_min, min(a_max, alpha_new));
303          if (alpha_u > alpha_u)
304              alpha.t = min(alpha_u) + 0.66*(alpha_u-alpha_u), alpha_t;
305          else
306              alpha.t = max(alpha_u) + 0.66*(alpha_u-alpha_u), alpha_t;
307          end
308      end
309      if bracketed
310          % v prípade, že sme počítali novy krok cez pomocnu funkciu (aux == 1),
311          % vratiame sa k vychodizm hodnotam
312          if aux
313              f1 = f1 + alpha_l*gcrit;
314              fu = fu + alpha_u*gcrit;
315              gl = gl + gcrit;
316              gu = gu + gcrit;
317          end
318      end
319      % v prípade, že nedoslo k dosťatočnemu uzeniu intervalu I, pristupime k
320      % bisekcie (iba ak je minimum obsiahnuté v I)
321      if bracketed
322          if (abs(alpha_u-alpha_u) >= 0.66 * width)
323              alpha_t = alpha_u + 0.5*(alpha_u - alpha_u);
324          end
325          width = width;
326          width = abs(alpha_u-alpha_u);
327      end
328  end
329 end

```

Funkcia `const_viol` počítajúca veľkosť porušenia prípustnosti vektora x , funkcia `merit_comp` počíta porušenie prípustnosti a podmienky komplementarity a funkcia `merit` počíta hodnotu merit funkcie (4.9). Nutné skomplíovať.

```

17 #define MAX2(A, B) ((A) < (B) ? (B) : (A))
18 #endif
19 #if !defined(MIN2)
20 #define MIN2(A, B) ((A) > (B) ? (B) : (A))
21 #endif
22 /* vstupne argumenty musia byt v tomto poradi:
23  * phs[1] = vektor (g_i(x)), (m 1) double - rezidua nerovnosti
24  * phs[2] = vektor (h_j(x)), (neq x 1) double - rezidua rovnosti
25  * phs[3] = typ normy na urcene velkosti porus. - string
26 */
27 */
28 void mexFunction(int nlhs,mxArray *plhs[],int nrhs,const mxArray *prhs[])
29 {
30     /* inicializacie premennych*/
31     /* smerniky na vstupy*/
32     double *fin, *fed;

```

```

33     double *res, *ppntr;
34     char *type;
35     mwIndex len, i, j, typ, spacing = 1;
36     msSize m, meq; /*rozmerystupnych vektorov*/
37     msSize typeLEN;
38     /* kontrola vstupov a vystupov */
39     if (nrhs == 3) {
40         if (nrhs > 3) {
41             mxErrMsgTxt("Funkcia CONST_VIOL potrebuje 3 vstupne argumenty");
42         }
43         if (nrhs > 1) {
44             mxErrMsgTxt("Prilis vela vstupnych argumentov");
45         }
46     }
47     /* rozmerystupnych vektorov */
48     m = (msSize)mxGetNumberOfElements(prhs[0]);
49     meq = (msSize)mxGetNumberOfElements(prhs[1]);
50
51     /*kopirovanie retazca zo vstupnej premennej 'typ'*/
52     typeLEN = mxGetN(prhs[2]) * sizeof(mxChar) + 1;
53     typeLEN = mxMalloc(typeLEN);
54     if (mxGetString(prhs[2], type, typeLEN) {
55         mexErrMsgTxt("Chyba pri konverzii premennej typ");
56     }
57     /*kontrola typu operaciei*/
58     if ((strcmp(type, "euc") == 0) || (strcmp(type, "2^n") == 0)) {
59         typ = 1;
60         typ = mxAlloc(typeLEN);
61         else if ((strcmp(type, "sup") == 0) || (strcmp(type, "max") == 0)) {
62             typ = 2;
63         } else {
64             mexErrMsgTxt("Neznamy typ normy");
65         }
66     }
67     /* alokacia pomocneho poliala*/
68     res = (double *)mxCreateDoubleMatrix(1, 1, mxREAL);
69     pLhs[0] = mxCreateDoubleMatrix(1, 1, mxREAL);
70     ppntr = mxGetPr(prhs[0]);
71     fin = mxGetPr(prhs[1]);
72     feq = mxGetPr(prhs[1]);
73
74     /* vytvorenie komplementarneho vektora */
75     j = 0;
76     for (i=0; i<n; i++) {
77         if (fin[i] < 0.0) {
78             res[i] = fin[i];
79             j = j + 1;
80         }
81     }
82     for (i=0; i<neq; i++) {
83         res[j+i] = feq[i];
84     }
85     j = j + neq;
86
87     /* pocitanie pozadovanej normy */
88     if (typ == 1) {
89         ppntr[0] = dnrm2(&j, res, &spacing);
90     } else if (typ == 2) {
91         i = idamax(&j, res, &spacing);
92         ppntr[0] = fabs(res[i-1]);
93     }
94
95     /* uvoľnenie premennej res */
96     mxfree(res);
97 }

```

1 /* Pocita porusenie 2 - 5 podmienky KKT sustavy

```

6 #define dnmr2 dnmr2_
7 #define idmaxx idmaxx_
8 #define dasum dasum_
9 #endif
10
11 #include "mex.h"
12 #include "blas.h"
13 #include <string.h>
14 #include <math.h>
15
16 #if !defined(MAX2)
17 #define MAX2(A, B) ((A) < (B)) ? (B) : (A)
18 #endif
19 #if !defined(MIN2)
20 #define MIN2(A, B) ((A) > (B)) ? (A)
21 #endif
22
23 /* kontrola typu operacie*/
24
25 prhs[0] = gradient (ang.) Lagrangeovej funkcie, (n x 1) double
26 prhs[1] = vektor (g_i(x)), (n x 1) double - rezidua nerovnosti
27 prhs[2] = vektor (Q_j(x)), (nq x 1) double - rezidua rovnosti
28 prhs[3] = vektor y, (m x 1) double
29
30 void mexFunction(int nlhs,mxArray *prhs[],int nrhs,const mxArray *prhs[])
31 {
32     /* inicializacie premennych */
33     double *grad, *neq, *eq, *y;
34     double *res, *pntc;
35     char *type;
36     mxIndex i, j, tip, spacing = 1;
37     mxIndex n, m, med;
38     mxSize typeLEN;
39
40     if (nrhs != 5) {
41         mxErrMsgTxt("Funkcia MERIT potrebuje 5 vstupnych argumentov");
42     }
43     if (nlhs > 1) {
44         mxErrMsgTxt("Prilis vela vstupnych argumentov");
45     }
46
47     /* rozmeny vektorov */
48     n = MAX2((mxIndex)mxGetN(prhs[0]), (mxIndex)mxEmpty(prhs[0])) * !mxIsEmpty(prhs[0]);
49     m = MAX2((mxIndex)mxGetN(prhs[1]), (mxIndex)mxEmpty(prhs[1])) * !mxIsEmpty(prhs[1]);
50     meq = MAX2((mxIndex)mxGetN(prhs[2]), (mxIndex)mxEmpty(prhs[2]));
51
52     if (MIN2((mxIndex)mxGetN(prhs[0]), (mxIndex)mxGetN(prhs[1])) > 1) {
53         mxErrMsgTxt("Premenna GRAD musi byt vektor");
54     }
55     if (MIN2((mxIndex)mxGetN(prhs[1]), (mxIndex)mxGetN(prhs[2])) > 1) {
56         mxErrMsgTxt("Premenna FIN musi byt vektor");
57     }
58     if (MIN2((mxIndex)mxGetN(prhs[2]), (mxIndex)mxGetN(prhs[1])) > 1) {
59         mxErrMsgTxt("Premenna FEQ musi byt vektor");
60     }
61
62     if (!m == MAX2((mxIndex)mxGetN(prhs[3]), (mxIndex)mxGetN(prhs[3])) * !mxIsEmpty(prhs[3])) {
63         mxErrMsgTxt("Vektor FIN a Y maju rozy pocet prvkov");
64     }
65
66     /* kopirovanie retazca zo vstupnej premennej 'typ' */
67     typelen = mxGetN(prhs[4]) * sizeof(mxChar) + 1;
68     type = mxMalloc(typeLen);
69     if (mxGetString(prhs[4], type, typeLen)) {
70         mxErrMsgTxt("Chyba pri konverzii premennej typ");
71     }
72
73     mexErrMsgTxt("Chyba pri konverzii premennej typ");
74
75     /*kopirovanie retazca zo vstupnej premennej 'typ' */
76     typeLen = mxGetN(prhs[3]) * sizeof(mxChar) + 1;
77     type = mxAlloc(typeLen);
78     if (mxGetString(prhs[3], type, typeLen)) {
79         mexErrMsgTxt("Chyba pri konverzii premennej typ");
80     }
81
82     mexErrMsgTxt("Chybe zadany typ operacie");
83
84     /* alokacia pomocnych polia a vystupnej matice */
85     res = (double *)mxCalloca(1+2*nmeq, sizeof(double));
86     plhs[0] = mxCreateDoubleMatrix(1, 1, mxREAL);
87     pptr = mxGetP(plhs[0]);
88     neq = mxGetP(prhs[0]);
89     eq = mxGetP(prhs[1]);
90     y = mxGetPr(prhs[2]);
91
92     /* vytvorenie komplementarneho vektoru */
93     res[0] = 0.0;
94     for (i=0; i<n; i++) {
95         res[i] = res[0] + fabs(y[i] * neq[i]); /* suet abs. hodnot fin */
96     }
97     j = 1;
98
99     /* priocitame hodnoty zapornych nerovnic a multiplicatorov */
100    for (i=0; i<n; i++) {
101        if (neq[i] < 0.0) {
102            if (res[i] < 0.0) {
103                res[i] = neq[i];
104                j = j + 1;
105            }
106            if (y[i] < 0.0) {
107                res[i] = y[i];
108                j = j + 1;
109            }
110        }
111
112        /* priocitame hodnoty rovnic */
113        for (i=0; i<med; i++) {
114            res[j+i] = eq[i];
115        }
116        j = j + meq;
117
118        /* pocitanie pozadovanej normy */
119        if (typ == 1) {
120            pptr[0] = dnmr2(&f0), res, &spacing); /* enklidovska norma */
121            j else if (typ == 2) {
122                i = idamax(&x, res, &spacing);
123                pptr[0] = fabs(res[i-1]);
124
125                /* uvolnenie premennej res */
126                mxfree(res);
127
128            }

```

```

/*kontrola typu operacie*/
73 if ((strcmp(type, "euc") == 0) || (strcmp(type, "2^") == 0)) {
74     typ = 1;
75 } else if ((strcmp(type, "sup") == 0) || (strcmp(type, "max") == 0)) {
76     typ = 2;
77 } else {
78     typ = 3;
79     mxerrMsgTxt("Chyba zadany typ operacie");
80 }
81 /* alokacia pomocnych poli a vystupnej matice */
82 res = (double *)mxAlloc((2*2+resq, sizeof(double)));
83 prhs[0] = mxCreateDoubleMatrix(1, 1, mxREAL);
84 pptr = mxGetPr(prhs[0]);
85 gradr = mxDerPr(pptr);
86 gradc = mxDerPr(prhs[0]);
87 neq = mxGetPr(prhs[1]);
88 eq = mxGetPr(prhs[2]);
89 y = mxGetPr(prhs[3]);
90 /* vytvorene komplementarneho vektora */
91 res[0] = 0.0;
92 for (i=0; i<n; i++) {
93     res[0] += fabs(y[i] * neq[i]); /* suet abs. hodnot fin.y */
94 }
95 rest[0] = res[0] + fabs(y[0] * neq[0]); /* vystup do vystupu */
96 /* norma gradientu Lagr. f. */
97 if (typ == 1) {
98     res[1] = dnorm2(kn, grad, &spacing); /* euklidovska norma */
99 } else if (typ == 2) { /* maximova norma */
100 }

/* funkcia f_comp počíta funkčnú hodnotu, prvú a druhú deriváciu Fischerovej funkcie.
   Funkcia f_comp potrebuje 4 vstupnych argumentov:
   1. Pocita funkcuu hodnotu, prvu a druhu derivaciu Fischerovej funkcie
   2. F(a, b) = a + b - sqrt(a^2 + b^2 + 2*mn)
   3. kompilovat pomocou mex -O -DDDEFINUNX f_comp.c -lmbblas */
4 /* Vstupne parametre >
5 prhs[0] : fin : hodnoty nerovnostnych ohrenici
6 prhs[1] = y : vektor multiplikatorov nerovnosti
7 prhs[2] = mn : per turbany parameter Fischerovej schemy
8 prhs[3] = typ : string, Jeden z FHD, DER1_A,
9 DER1_B, ALL.
10
11 #if !defined(WIN32)
12 #define dnorm2 dnm2_
13 #define idamax idam_
14 #define dasum dasum_
15 #define dasum dasum_
16 #endif
17 #if !defined(MAT3)
18 #define MAX(A, B, C) (((A) < (B)) ? ((B) < (C)) ? (C) : (B) : ((A) < (C) ? (C) : (A)))
19 #define MIN(A, B, C) (((A) > (B)) ? ((B) > (C)) ? (C) : (B) : ((A) > (C) ? (C) : (A)))
20 #endif
21 #include "mex.h"
22 #include "blas.h"
23 #include <string.h>
24 #include <math.h>
25 #include
26
27 #if !defined(MA2)
28 #define MAX2(A, B) ((A) < (B) ? (B) : (A))
29 #endif
30 #if !defined(MIN2)
31 #define MIN2(A, B) ((A) > (B) ? (B) : (A))
32 #endif

```

Funkcia f_comp počíta funkčnú hodnotu, prvú a druhú deriváciu Fischerovej funkcie. Zdrojový kód je nutné skompilovať.

```

1 /* Pocita funkcuu hodnotu, prvu a druhu derivaciu Fischerovej funkcie
2 F(a, b) = a + b - sqrt(a^2 + b^2 + 2*mn)
3 kompilovat pomocou mex -O -DDDEFINUNX f_comp.c -lmbblas */
4 /* Vstupne parametre >
5 prhs[0] : fin : hodnoty nerovnostnych ohrenici
6 prhs[1] = y : vektor multiplikatorov nerovnosti
7 prhs[2] = mn : per turbany parameter Fischerovej schemy
8 prhs[3] = typ : string, Jeden z FHD, DER1_A,
9 DER1_B, ALL.
10
11 #if !defined(WIN32)
12 #define dnorm2 dnm2_
13 #define idamax idam_
14 #define dasum dasum_
15 #define dasum dasum_
16 #endif
17 #if !defined(MAT3)
18 #define MAX(A, B, C) (((A) < (B)) ? ((B) < (C)) ? (C) : (B) : ((A) < (C) ? (C) : (A)))
19 #define MIN(A, B, C) (((A) > (B)) ? ((B) > (C)) ? (C) : (B) : ((A) > (C) ? (C) : (A)))
20 #endif
21 #include "mex.h"
22 #include "blas.h"
23 #include <string.h>
24 #include <math.h>
25 #include
26
27 #if !defined(MA2)
28 #define MAX2(A, B) ((A) < (B) ? (B) : (A))
29 #endif
30 #if !defined(MIN2)
31 #define MIN2(A, B) ((A) > (B) ? (B) : (A))
32 #endif
33 void mexFunction(int nlhs, mxArray *prhs[], int nrhs, const mxArray *prhs[])
34 {
35     /* inicializacie premennych */
36     double *fin, *y, mn;
37     double *pptr, s, sqrt_2mu, sqrt_f;
38     char *type;
39     mwIndex i, typ, spacing = 1;
40     mwIndex m;
41     mwSize typeLEN;
42
43     if (nrhs != 4) {
44         mxErrMsgTxt("Funkcia F_COMP potrebuje 4 vstupnych argumentov");
45     }
46 }
47 /* rozmery vektorov */
48 m = (mwIndex)mxGetNumberOfElements(prhs[0]);
49 if (MIND((mwIndex)mxGetM(prhs[0]), (mwIndex)mxGetN(prhs[0])) > 1) {
50     mxErrMsgTxt("Vektor FIN a Y maju rozny pocet prvkov");
51     if (MIN2((mwIndex)mxGetM(prhs[1]), (mwIndex)mxGetN(prhs[1])) > 1) {
52         mxErrMsgTxt("Premenna F_IN musi byt vektor");
53     }
54     if (MIN2((mwIndex)mxGetM(prhs[1]), (mwIndex)mxGetN(prhs[1])) > 1) {
55         mxErrMsgTxt("Premenna Y musi byt vektor");
56     }
57     if (m != (mwIndex)mxGetNumberOfElements(prhs[1])) {
58         mxErrMsgTxt("Vektor FIN a Y maju rozny pocet prvkov");
59     }
60 }
61 /* kopirovanie retazca zo vstupnej premennej 'typ' */
62 type = mxAlloc(sizeof(mxChar) + 1);
63 type = mxMalloc(typeLEN);
64

```

```

65     if (inxGetString(prhs[3], type, typeLen) {
66         mexErrMsgTxt("Chyba pri konverzii premennej typ");
67     }
68     /*kontrola typu operacie*/
69     if (strcmp(type, "fmod") == 0) {
70         typ = 1;
71         if ((strcmp(type, "deria") == 0) || (strcmp(type, "der1_at") == 0)) {
72             typ = 2;
73         } else if ((strcmp(type, "derib") == 0) || (strcmp(type, "der1_bt") == 0)) {
74             typ = 3;
75         } else if (strcmp(type, "all") == 0) {
76             typ = 4;
77         } else {
78             mexErrMsgTxt("Chybone zadany typ operacie");
79         }
80     }
81     /* kontrola vystupnych premennych */
82     if (typ < 4 && nlhs > 1) {
83         mxErrMsgTxt("Prvnis nrlis vela vystupnych argumentov");
84     } else if (typ == 4 && nlhs > 3) {
85         mxErrMsgTxt("Prvnis nrlis vela vystupnych argumentov");
86     }
87 }
88 /* priradenie smernikov */
89 fin = mxGetPr(prhs[1]);
90 y = mxGetPr(prhs[1]);
91 mu = fabm(mxDerScalar(prhs[2]));
92 sqrt_2mu = sqrt(2.0*mu);
93 if (typ < 4) {
94     /* alokacia pomocnych poli a vystupnej matice */
95     plhs[0] = mxCreateDoubleMatrix(1, mxREAL);
96     pptr = mxGetPr(plhs[0]);
97     for (i=0; i<n; i++) {
98         /* priprava pomocnych poli a vystupnej matice */
99         plhs[0] = mxCreateDoubleMatrix(1, mxREAL);
100        pptr = mxGetPr(plhs[0]);
101    }
102    s = MAX3(fabs(fin[i]), fabs(y[i]), sqrt_2mu );
103    sqrt_f = ssqrt( (fin[i]/s)*(fin[i]/s) +
104                    (y[i]/s)*(y[i]/s) +
105                    2*mu/s/s );
106    if (typ == 1) {
107        pptr[i] = fin[i] + y[i] - sqrt_f; /* funkna hodnota */
108    } else if (typ == 2) {
109        pptr[i] = 1 - fin[i] + y[i] - sqrt_f; /* derivacia podla a */
110    } else if (typ == 3) {
111        pptr[i] = 1 - y[i] / sqrt_f; /* derivacia podla b */
112    }
113 } else if (typ == 4) {
114     /* alokacia pomocnych poli a vystupnej matice */
115     plhs[0] = mxCreateDoubleMatrix(n, 1, mxREAL);
116     pptr = mxGetPr(plhs[0]);
117     /* alokacia dodatocnej pamate pre ostatne vystupy */
118     double *pptr1, *pptr2;
119     pptr1 = mxCreateDoubleMatrix(n, 1, mxREAL);
120     pptr2 = mxCreateDoubleMatrix(n, 1, mxREAL);
121     pptr1 = mxGetPr(plhs[1]);
122     pptr2 = mxGetPr(plhs[2]);
123     pptr1 = mxCreateDoubleMatrix(n, 1, mxREAL);
124     pptr2 = mxGetPr(plhs[2]);
125     pptr1 = mxGetPr(plhs[1]);
126     pptr2 = mxGetPr(plhs[2]);
127     for (i=0; i<n; i++) {
128         s = MAX3(fabs(fin[i]), fabs(y[i]), sqrt_2mu );
129         sqrt_f = ssqrt( (fin[i]/s)*(fin[i]/s) +
130                         (y[i]/s)*(y[i]/s) +
131                         2*mu/s/s );
132         pptr1[i] = fin[i] + y[i] - sqrt_f; /* funkna hodnota */
133         pptr1[i] = 1 - fin[i] + y[i] / sqrt_f; /* derivacia podla a */
134         pptr2[i] = 1 - y[i] / sqrt_f; /* derivacia podla b */
135     }
136 }
137 }

```