

UNIVERSITATEA BABEȘ-BOLYAI CLUJ-NAPOCA  
FACULTATEA DE MATEMATICĂ ȘI INFORMATICĂ



REZUMAT TEZĂ DE DOCTORAT

**Contribuții la studiul funcțiilor de tip convex  
și în optimizarea fracționară**

Conducător științific  
Prof. Dr. Radu Precup

Doctorand  
Alexandru Orzan

Cluj-Napoca  
2024

---

# Cuprins

---

<b>Introducere</b>	<b>4</b>
<b>Capitolul 1</b>	
<b>Convexitate generalizată pentru funcții vectoriale</b>	<b>12</b>
1.1 Preliminarii și proprietăți ale conurilor convexe . . . . .	14
1.2 Convexitate generalizată . . . . .	15
1.2.1 Convexitate generalizată pentru funcții scalare . . . . .	15
1.2.2 Funcții $C$ -convexe, $C$ -cvasiconvexe și explicit $C$ - cvasiconvexe . . . . .	17
1.2.3 Funcții semistrict $C$ -cvasiconvexe . . . . .	18
1.3 Caracterizarea funcțiilor semistrict și explicit $C$ -cvasiconvexe cu ajutorul funcțiilor neliniare de scalarizare . . . . .	20
<b>Capitolul 2</b>	
<b>Proprietăți ale funcțiilor fracționare</b>	<b>22</b>
2.1 Preliminarii . . . . .	23
2.2 Multifuncții afine în sens Tan . . . . .	23
2.2.1 Funcții vectoriale fracționar afine . . . . .	24
2.2.2 Funcții multivoce fracționar afine . . . . .	25
2.3 Funcții multivoce afine în sens Gorokhovik . . . . .	26
2.3.1 Funcții fracționar afine multivoce . . . . .	27
2.4 Proprietăți de păstrare a convexității . . . . .	29
2.4.1 Funcții multivoce generale . . . . .	29
2.4.2 Funcții multivoce fracționar afine . . . . .	30
<b>Capitolul 3</b>	
<b>Algoritmi de aproximare de tip Dinkelbach pentru probleme</b>	

**fracționare** **31**

3.1 Probleme de optimizare fracționară și algoritmul lui Dinkelbach . . . . . 32

3.2 Algoritmul lui Dinkelbach cu eroare fixă . . . . . 34

3.3 Algoritmul lui Dinkelbach cu eroare convergentă la zero . . . . . 35

3.4 Algoritmul Dinkelbach-Ekeland . . . . . 36

3.5 Condiții suficiente pentru (PS) . . . . . 37

**Capitolul 4**

**Algoritmul lui Dinkelbach pe componente pentru probleme fracționare** **39**

4.1 Problema generală de optimizare . . . . . 40

4.2 Relații între minime globale și parțiale . . . . . 41

4.3 Algoritmul lui Dinkelbach pe componente . . . . . 42

4.4 Convergența algoritmului lui Dinkelbach pe componente . . . . . 43

**Bibliografie** **46**

---

# Introducere

---

*Prezenta teză de doctorat a  
început sub îndrumarea  
regretatului profesor Nicolae  
Popovici*

Optimizarea este o bine-cunoscută ramură a matematicii care are drept obiect determinarea soluțiilor optime dintr-o mulțime admisibilă de soluții, din cadrul unei probleme de minimizare sau maximizare pentru o funcție dată, luând în considerare și posibile restricții. Datorită numeroaselor sale aplicații, optimizarea reprezintă un domeniu deosebit de important atât în matematică cât și în alte domenii conexe.

Dintre aceste domenii amintim următoarele (vezi, e.g., Frenk și Schaible [26], Schaible [72], Shen și Yu [75, 76], Hillier și Lieberman [41], Khisty și Lall [46] și alte titluri citate în aceste lucrări).

*Cercetarea operațională:* Optimizarea este o știință care stă la baza cercetării operaționale, facilitând astfel afacerile în procese decizionale legate de alocarea resurselor, planificarea producției, gestionarea stocurilor și logistică;

*Inginerie:* Inginerii folosesc tehnici de optimizare pentru a proiecta sisteme, structuri și procese eficiente, cum ar fi optimizarea formei aripilor aeronavelor sau proiectarea clădirilor energo-eficiente;

*Economie și Finanțe:* În economie, modelele de optimizare sunt folosite pentru a studia și prognoza comportamentul economic. În domeniul finanțelor, diferite modele matematice de optimizare sunt deasemenea încorporate pentru gestionarea riscului;

*Transport:* Optimizarea este esențială pentru planificarea rutelor, programarea vehiculelor și gestionarea lanțurilor de aprovizionare;

*Energie și mediu:* Optimizarea este de o importanță covârșitoare la reglarea consumului de energie, reducerea emisiilor și proiectarea sistemelor

durabile în domenii precum integrarea energiei regenerabile și modelarea mediului înconjurător.

Dintre diversele teme care fac obiectul optimizării amintim, printre altele, programarea liniară, programarea convexă, programarea neliniară, programarea discretă și programarea dinamică. La fel ca în multe alte domenii matematice, optimizarea integrează concepte și rezultate din diverse domenii conexe, precum analiza funcțională, analiza convexă, teoria jocurilor etc., fiind, totodată, deschisă și către algoritmi și modelări numerice.

Urmând curentul impus și de alte domenii matematice, optimizarea a încorporat în mod natural liniaritatea, evoluție marcată de apariția programării liniare ca componentă semnificativă în cadrul domeniului optimizării.

În mod firesc, următorul pas în acest domeniu, crucial pentru abordarea eficientă a problemelor practice, a implicat abordarea non-liniarității și, în consecință, a funcțiilor neliniare.

Acest lucru încă reprezintă o provocare și ar fi fost imposibil de întrezărit fără pasul intermediar oferit de analiza convexă. Convexitatea joacă un rol fundamental în optimizare deoarece simplifică procesul de rezolvare a problemelor, garantează existența punctelor de optim global și permite utilizarea eficientă a multor algoritmilor.

Una dintre cele mai populare ramuri ale optimizării este optimizarea fracționară. Acest subdomeniu se ocupă cu optimizarea funcțiilor care implică fracții sau expresii raționale și este aplicat cu precădere în economie (programare fracționară), inginerie, sănătate (alocare de resurse), proiectarea rețelelor (rute optime pentru transmiterea datelor), sistemele de control optim (pentru procese care implică dinamici de ordin fracționar, cum ar fi circuitele electrice, reactoarele chimice sau sistemele mecanice), managementul lanțurilor de aprovizionare, matematică (Ecuații Diferențiale Fraționare), studii de mediu (optimizarea utilizării terenurilor, alocarea fondurilor de conservare sau proiectarea coridoarelor pentru fauna sălbatică) etc.

Problema tipică de optimizare fracționară (denumită în mod obișnuit problemă de programare fracționară sau program fracționar) este definită în felul următor:

$$\frac{A(x)}{B(x)} \longrightarrow \min_{x \in D},$$

unde  $A$  și  $B$  sunt funcții definite pe o mulțime nevidă  $D$  iar  $B(x) \neq 0$  pentru orice  $x \in D$ . Rezolvarea acestei probleme se reduce la determinarea unei perechi  $(\lambda^*, x^*)$ , în care  $\lambda^*$  reprezintă valoarea minimă a câtului  $A/B$ , și  $x^*$

este punctul de minim corespunzător., i.e.,

$$\lambda^* = \frac{A(x^*)}{B(x^*)} = \min_D \frac{A}{B}.$$

Dintr-o perspectivă istorică, așa cum se menționează în lucrarea lui Frenk și Schaible [26], este demn de remarcat faptul că una dintre primele apariții ale programării fracționare, cu toate că nu fusese denumită în mod explicit astfel, a apărut în 1937 odată cu modelul de echilibru al economiei în creștere al lui John von Neumann. Modelul calculează rata de creștere economică selectând cea mai mare valoare dintre cele mai mici rapoarte producție-intrare din surse multiple. Cu toate acestea, cu excepția unui număr mic de lucrări individuale, precum cele ale lui von Neumann, un studiu cuprinzător al programării fracționare a început abia mult mai târziu. Influența mai multor autori cu contribuții semnificative în domeniu la acea perioadă este de asemenea evidențiată în lucrarea lui Frenk și Schaible [26].

Prima monografie ce tratează programarea fracționară, intitulată *Analyse und Anwendungen von Quotientenprogrammen, Ein Beitrag zur Planung mit Hilfe der nichtlinearen Programmierung*, a fost scrisă de Schaible în 1978. După cum este menționat în lucrarea lui Frenk și Schaible [26], aceasta a fost urmată de alte două monografii care s-au concentrat exclusiv pe programarea fracționară, prima dintre ele fiind scrisă de Craven în 1988, iar cealaltă, de Stancu-Minasian în 1997.

De atunci, mulți cercetători au depus eforturi considerabile în domeniul optimizării fracționare. Contribuțiile remarcabile includ lucrările lui Avriel et al. [2], Cambini și Martein [14], Stancu-Minasian [79], Elbenani și Ferland [21], Crouzeix [15, 16], Hadjisavvas [26], Schaible [71, 72], Rodenas [69], Shi [77], Boț et al. [10, 11], și Tammer [81], precum și alte titluri citate în aceste lucrări.

Metodele și tehnicile de lucru dezvoltate în cadrul optimizării fracționare au generat un interes semnificativ legat de proprietățile funcțiilor  $f$  și  $g$ , cum ar fi convexitatea, concavitățile, mărginirea, liniaritatea etc. Prin urmare, primele două capitole ale tezei tratează acest subiect.

În aceste capitole, introducem un nou concept de semistrict cvasiconvexitate pentru funcții vectoriale, definite pe o mulțime nevidă și convexă dintr-un spațiu liniar real  $X$  cu valori într-un spațiu liniar real topologic  $Y$ , parțial ordonat de un con convex solid  $C$ . Ulterior, oferim o caracterizare a acestor funcții folosind funcția de scalarizare neliniară introdusă de Gerstewitz (Tammer) în 1983. Adicional, furnizăm câteva caracterizări de conservare a convexității prin imaginile directe și inverse pentru două clase speciale de multifuncții fracționare.

O direcție importantă de cercetare în cadrul optimizării fracționare se concentrează pe dezvoltarea algoritmilor pentru rezolvarea problemelor fracționare. Printre numeroșii algoritmi care abordează problemele de tip fracționar, vechi și noi (consultați, de exemplu, lucrările lui Boț și Csetnek [10], Boț, Dao și Li [11], Boyd et al. [12], Geissler et al. [28], Goldstein et al. [31], Kleinert și Schmidt [47] precum și titlurile citate în aceste lucrări), algoritmul lui Dinkelbach (Dinkelbach [20]) rămâne unul dintre cei mai cunoscuți. Așa cum este menționat în lucrarea lui Tammer și Ohlendorf [81, Sec. 3], acesta are la bază algoritmul lui Jagannathan din 1966 pentru problemele fracționare liniare. Algoritmul lui Dinkelbach este un procedeu folosit pentru a rezolva probleme de programare fracționară prin transformarea problemei inițiale (de tip fracționar) într-o problemă parametrică non-fracționară și, în consecință, cea de-a doua parte a tezei este dedicată acestui subiect.

În această parte se prezintă două variante aproximative ale algoritmului lui Dinkelbach (cu o eroare dată  $\varepsilon > 0$  și cu erori convergente către zero), alături de o nouă versiune a algoritmului, algoritmul Dinkelbach-Ekeland, ce încorporează principiul variațional al lui Ekeland.

Ultimul capitol al tezei, prezintă o nouă versiune a algoritmului lui Dinkelbach, numită algoritmul lui Dinkelbach pe componente. Spre deosebire de versiunea originală, această variantă este concepută pentru a aborda funcțiile fracționare care depind de două variabile. Contribuția acestui capitol constă în stabilirea convergenței algoritmului componential.

Teza are patru capitole și este structurată pe secțiuni și subsecțiuni.

### **Capitolul 1:** Convexitate generalizată pentru funcții vectoriale

În primul capitol introducem noul concept de semistrict *cvasiconvexitate* pentru funcții vectoriale, definite pe o mulțime nevidă și convexă dintr-un spațiu liniar real  $X$  cu valori într-un spațiu liniar real topologic  $Y$ , parțial ordonat de un con convex solid  $C$ . Secțiunea 1.1 se concentrează pe prezentarea cadrului general și a noțiunilor care se vor dovedi a fi de interes în continuare. În Secțiunea 1.2, revizuim câteva noțiuni clasice de convexitate generalizată atât pentru funcții scalare cât și vectoriale, și enunțăm conceptul de semistrict *cvasiconvexitate*. În cele din urmă, în Secțiunea 1.3, prezentăm rezultatul nostru principal care caracterizează funcțiile vectoriale semistrict  $C$ -quasiconvexe folosind funcțiile de scalarizare neliniare. În plus, în cazul particular finit dimensional al spațiului euclidian real  $Y = \mathbb{R}^m$ , ordonat de conul standard  $C = \mathbb{R}_+^m$ , stabilim o relație între conceptul nostru de semistrict  $C$ -quasiconvexitate și alte concepte cunoscute din literatură.

Contribuțiile noastre în acest capitol sunt prezentate mai jos. În Secțiunea 1.2: Definiția 1.2.8, Lema 1.2.11, Lema 1.2.12, Teorema 1.2.13, Lema 1.2.16,

Teorema 1.2.19, Teorema 1.2.21. În Secțiunea 1.3 avem: Teorema 1.3.1 și Corolarul 1.3.2.

Toate rezultatele menționate anterior sunt originale și sunt conținute în lucrarea Günther, Orzan și Popovici [35].

## Capitolul 2: Proprietăți ale funcțiilor fracționare

În acest capitol prezentăm rezultate de conservare a convexității prin imagini directe și inverse pentru două clase speciale de multifuncții fracționare. Capitolul este împărțit în patru secțiuni.

Secțiunea 2.1 este dedicată prezentării noțiunilor și rezultatelor generale de analiză multivocă și convexă ce vor fi folosite pe parcurs.

Secțiunea 2.2 studiază conceptul de multifuncție afină în sens Tan [84] și extinde rezultatele clasice stabilite de Rothblum [70] în cadrul spațiilor euclidiene finite-dimensionale la spații liniare reale. În ultima parte a acestei secțiuni se furnizează o serie de proprietăți de păstrare a convexității.

În Secțiunea 2.3, examinăm o altă noțiune de multifuncție afină, anume cea introdusă de Gorokhovich [33, 34] și prezentăm o serie de rezultate care vor fi de o importanță semnificativă pentru secțiunea următoare.

Ultima Secțiune 2.4 furnizează o serie de rezultate de conservare a convexității mulțimilor atât prin multifuncții generale cât și prin clasele noastre de multifuncțiile afine.

Contribuțiile noastre în acest capitol sunt prezentate mai jos. În Secțiunea 2.2: Propoziția 2.2.2, Teorema 2.2.3, Corolarul 2.2.4, Propozițiile 2.2.6, 2.2.7, 2.2.8, Teorema 2.2.10, Teoremele 2.2.11, 2.2.12, Corolarul 2.2.13. În Secțiunea 2.3 avem: Lema 2.3.6, Propoziția 2.3.7. În ultima Secțiune 2.4, avem: Propozițiile 2.4.1, 2.4.3, Corolarul 2.4.2, Teorema 2.4.4, 2.4.6, Corolarul 2.4.5, Teorema 2.4.7, Corolarile 2.4.8, 2.4.9.

Toate rezultatele menționate anterior sunt originale și sunt conținute în lucrările Orzan și Popovici [60, 61] și Orzan [59].

## Capitolul 3: Algoritmi de aproximare de tip Dinkelbach pentru probleme fracționare

În cel de-al treilea capitol al tezei, prezentăm variante aproximative ale algoritmului lui Dinkelbach pentru probleme de optimizare fracționară neliniară în cadrul general al spațiilor Banach. Capitolul este format din cinci secțiuni.

Secțiunea 3.1 vine ca o introducere în cadrul general de lucru și în algoritmul original al lui Dinkelbach. În Secțiunea 3.2, abordăm cazul în care punctul de minim pentru problema noastră de optimizare poate fi determinat cu o eroare specificată ( $\varepsilon > 0$ ), și stabilim, de asemenea, o condiție suficientă pentru atingerea valorii minime a funcționalei  $A/B$ . În Secțiunea



3.3, prezentăm o altă versiune a algoritmului Dinkelbach, în care eroarea tinde către zero, demonstrând convergența sa către soluția problemei noastre de optimizare, sub condiția de compactitate Palais-Smale.

În Secțiunea 3.4 prezentăm noul nostru algoritm, algoritmul de aproximare Dinkelbach-Ekeland, pentru probleme de optimizare fracționară, care utilizează principiul variațional al lui Ekeland pentru a genera șirul  $(x_k)$  implicat în procesul iterativ.

Ultima secțiune, Secțiunea 3.5, oferă condiții suficiente care permit îndeplinirea cerinței Palais-Smale și, în consecință, stabilește rezultatul nostru final referitor la convergența algoritmului Dinkelbach-Ekeland.

Contribuțiile noastre în acest capitol sunt prezentate mai jos. În Secțiunea 3.2: Teoremele 3.2.2, 3.2.3. Secțiunea 3.3 prezintă: Teoremele 3.3.2 și 3.3.3. În Secțiunea 3.4 avem: Algoritmul 3.4.1 și Teorema 3.4.2. Ultima Secțiune 3.5 prezintă: Lemele 3.5.1, 3.5.2, Propoziția 3.5.3 și Teorema 3.5.4.

Toate rezultatele menționate anterior sunt originale și sunt conținute în lucrarea Orzan și Precup [62].

**Capitolul 4:** Algoritmul lui Dinkelbach pe componente pentru probleme fracționare

În ultimul capitol al tezei, introducem un algoritm de aproximare de tip Dinkelbach, dezvoltat special pentru calculul punctelor de minim parțial în problemele de optimizare fracționară. Capitolul este împărțit în patru secțiuni.

Secțiunea 4.1 prezintă noțiunile de bază necesare pentru înțelegerea problemelor de optimizare fracționară în care funcția obiectiv (raport a două funcții) este definită pe produsul cartezian a două spații normate reale, anume  $X$  și  $Y$ . Cel de-al doilea obiectiv al acestei secțiuni este identificarea punctelor de minim parțial, puncte din  $X \times Y$  în care o variabilă minimizează funcția obiectiv în timp ce cealaltă rămâne constantă. În Secțiunea 4.2 stabilim câteva conexiuni între punctele de minim global și parțial, și explorăm, de asemenea, cazul în care  $A(x, y)$  și  $B(x, y)$  au variabile separate, demonstrând că în acest context, minimul parțial coincide cu minimul global. În plus, oferim un rezultat similar pentru spațiile euclidiene finite-dimensionale spre sfârșitul acestei secțiuni. Secțiunea 4.3 debutează prin introducerea algoritmului original Dinkelbach, aplicat la funcții cu două variabile iar, mai apoi, prezintă varianta noastră componentială a algoritmului lui Dinkelbach și investighează câteva dintre limitările acestuia.

Ultima Secțiune 4.4, are drept obiectiv convergența algoritmului nostru componential. În cadrul ei, se demonstrează că prin impunerea unor condiții asupra spațiilor și funcțiilor implicate, cum ar fi continuitatea de tip Lipschitz, diferențiabilitatea Fréchet parțială și coercivitatea, algoritmul converge

către un minim parțial.

Contribuțiile noastre în acest capitol sunt prezentate mai jos. În Secțiunea 4.2 avem: Propozițiile 4.2.1, 4.2.2 și 4.2.3. În Secțiunea 4.3: Algoritmii 4.3.1, Propoziția 4.3.2. În ultima Secțiune 4.4 prezentăm: Teoremele 4.4.1, 4.4.2 și 4.4.4.

Toate rezultatele menționate anterior sunt originale și sunt conținute în lucrarea Günther, Orzan și Precup [36].

\*\*\*

Lucrările doctorandului:

- Orzan A. A new class of fractional type set-valued functions. Carpathian J. Math. 2009;35:79–84.
- Orzan A, Popovici N. Convexity-preserving properties of set-valued ratios of affine functions. Stud. Univ. Babeș-Bolyai Math. 2023;66:591–602.
- Orzan A, Popovici N. Characterization of certain fractional-type set-valued functions. Optimization. DOI: 10.1080/02331934.2023.2174377.
- Orzan A, Precup R. Dinkelbach type approximation algorithms for nonlinear fractional optimization problems, Numerical Functional Analysis and Optimization. 2023;44(9):954–969.
- Günther C, Orzan A, Precup R. Componentwise Dinkelbach algorithm for nonlinear fractional optimization problems. Optimization, DOI: 10.1080/02331934.2023.2256750.
- Günther C, Orzan A, Popovici N. A new concept of semistrict quasi-convexity for vector functions, submitted 2023.

Comunicările științifice ale doctorandului cu abstract:

- *On a special class of fractional set-valued functions*, Romanian Itinerant Seminar on Mathematical Analysis and its Applications (RISMAA), Cluj-Napoca, 20-22 aprilie, 2018. <https://www.cs.ubbcluj.ro/wp-content/uploads/RISMAA-2018-Abstracts.pdf>
- *On a special class of fractional type set-valued functions*, 13th Joint Conference on Mathematics and Computer Science (the 13th MaCS), October 1-3, 2020, ELTE, Hungary. [http://macs2020.elte.hu/wpcontent/uploads/2020/10/programme\\_overview.pdf](http://macs2020.elte.hu/wpcontent/uploads/2020/10/programme_overview.pdf)

- *Dinkelbach type approximation algorithms for nonlinear fractional optimization problems*, 14th Joint Conference on Mathematics and Computer Science (the 14th MaCS), November 24-27, 2022, Cluj-Napoca, Romania. [https://www.cs.ubbcluj.ro/macs/2022/abs/macs2022\\_abstracts.pdf](https://www.cs.ubbcluj.ro/macs/2022/abs/macs2022_abstracts.pdf)
- *Approximation Algorithms of Dinkelbach type for fractional optimization problems*, The joint seminar of the groups algorithmic optimization, numerical analysis, and scientific computing, Leibniz University, February 23, Hannover, Germany, 2023.
- *Componentwise Dinkelbach algorithm for nonlinear fractional optimization problems*, 17th International Conference on Applied Mathematics and Computer Science, July 11-13, 2023, Cluj-Napoca, Romania. <https://docs.google.com/spreadsheets/d/e/2PACX-1vTtFLtlpmFkAL9zMmrj-Lg3HxToczM3K3FZJXaoVieLtMQhPepYajD3BG3McZEXKsR2CnZWLxhXrKkb/pubhtml#>

\* \* \*

### **Cuvinte cheie**

Convexitate generalizată, multifuncții fracționar-afine, funcții ce păstrează convexitatea, optimizare fracționară, algoritmi de tip Dinkelbach, Principiul lui Ekeland, minim parțial.

---

# Capitolul 1

## Convexitate generalizată pentru funcții vectoriale

---

Noțiunea generală de convexitate a funcțiilor este des recunoscută ca fiind un factor limitativ în multe situații practice, așa cum este demonstrat în lucrări precum cea a lui Cambini și Martein [14]. În răspuns la această limitare, mai mulți cercetători au introdus clase mai largi de funcții, cunoscute sub numele de funcții convexe generalizate. Aceste funcții generalizat convexe (și concave) conțin clasa funcțiilor convexe, moștenind totodată proprietăți valoroase de la acestea dar se bucură și de condiții de existență mai relaxate. Funcțiile generalizat convexe au aplicații într-o varietate de domenii, inclusiv în economie pentru reprezentarea preferințelor și a funcțiilor de utilitate, în finanțe pentru sarcini precum optimizarea portofoliului, gestionarea riscurilor și evaluarea activelor, precum și în inginerie pentru aplicații în design structural, optimizarea proceselor și prelucrarea semnalelor etc.

În ceea ce privește aplicațiile matematice, aceste funcții sunt larg recunoscute și studiate în special în contextul optimizării scalare, vectoriale și multivoce. Referințele semnificative în această direcție includ lucrările lui Avriel *et al.* [2], Bagdasar și Popovici [3], Crouzeix, Martínez-Legaz și Volle [17], Flores-Bazán [23], Flores-Bazán și Vera [25], Göpfert *et al.* [32], Günther și Tammer [39, 40], Jahn [43], Khan, Tammer și Zălinescu [45], La Torre și Popovici [49], Luc [53], Luc și Schaible [54], Popovici [64], împreună cu referințele citate în aceste lucrări.

Printre conceptele foarte cunoscute de convexitate generalizată pentru funcții vectoriale, definite pe o submulțime nevidă și convexă  $D$  dintr-un spațiu liniar real  $X$ , cu valori într-un spațiu topologic liniar real  $Y$ , ordonat de un con convex  $C$ , se numără noțiunile de  $C$ -convexitate,  $C$ -cvasiconvexitate și explicit  $C$ -cvasiconvexitate, introduse de Luenberger [55], Borwein [9], Luc [53], și Popovici [63].

Aceste concepte de  $C$ -convexitate,  $C$ -cvasiconvexitate și explicit  $C$ -

cvasiconvexitate reprezintă generalizări naturale ale noțiunilor clasice de convexitate, cvasiconvexitate și explicit cvasiconvexitate, care sunt aplicate în mod obișnuit funcțiilor cu valori reale. Această extindere provine din faptul că în contextul specific al spațiului euclidian real de dimensiune finită  $Y = \mathbb{R}^m$ , parțial ordonat de conul uzual de ordine  $C = \mathbb{R}_+^m$ , o funcție vectorială  $f = (f_1, \dots, f_m)$  este  $C$ -convexă ( $C$ -cvasiconvexă, explicit  $C$ -cvasiconvexă) dacă și numai dacă componentele sale scalare au această proprietate.

Sigur că o astfel de abordare pe componente nu este realizabilă, în general, în spații oarecare. Prin urmare, un domeniu de cercetare interesant în cadrul optimizării vectoriale se concentrează pe caracterizarea convexității generalizate a funcțiilor vectoriale prin valorificarea principiilor clasice de convexitate generalizată ale anumitor funcții cu valori reale. Această abordare a fost explorată de cercetători precum Benoist, Borwein și Popovici [6], La Torre, Popovici și Rocca [50], Luc [53], și Günther și Popovici [37, 38].

În acest prim capitol introducem un nou concept de semistrict cvasiconvexitate pentru funcții vectoriale, definite pe o mulțime nevidă și convexă dintr-un spațiu liniar real  $X$  cu valori într-un spațiu liniar real topologic  $Y$ , parțial ordonat de un con convex solid  $C$ . Rezultatul principal din această secțiune a tezei este caracterizarea funcțiilor semistrict  $C$ -cvasiconvexe folosind funcțiile de scalarizare semistrict cvasiconvexe  $\sigma_a \circ f$ .

Capitolul este împărțit în trei secțiuni. **Secțiunea 1.1** prezintă noțiuni și rezultate fundamentale care se vor dovedi a fi de interes în continuare.

În **Secțiunea 1.2**, reamintim câteva noțiuni clasice de convexitate generalizată atât pentru funcțiile cu valori reale, cât și pentru cele cu valori vectoriale și enunțăm noul nostru concept de semistrict cvasiconvexitate pentru funcții vectoriale.

În finalul capitolului, **Secțiunea 1.3**, prezentăm rezultatul nostru central, ce oferă o caracterizare a funcțiilor vectoriale semistrict  $C$ -cvasiconvexe cu ajutorul funcțiilor de scalarizare neliniare. Mai mult, în contextul spațiului euclidian real finit-dimensional  $Y = \mathbb{R}^m$ , parțial ordonat de conul uzual de ordine  $C = \mathbb{R}_+^m$ , stabilim legătura dintre noul nostru concept și alte noțiuni cunoscute în literatură, respectiv, semistrict cvasiconvexitate pe componente și explicit cvasiconvexitate pe componente.

Rezultatele prezentate în această parte a tezei au fost incluse în lucrarea Günther, Orzan și Popovici [35].

## 1.1 Preliminarii și proprietăți ale conurilor convexe

În prima secțiune a acestui capitol vom prezenta o serie de definiții și rezultate cheie legate de convexitate generalizată și conuri convexe. Pentru a facilita înțelegerea, începem prin a considera  $X$  un spațiu liniar real,  $Y$  un spațiu liniar topologic real,  $D \subseteq X$  o mulțime nevidă și convexă, și  $C \subseteq Y$  un con convex, i.e.,  $0 \in C = \mathbb{R}_+ \cdot C = C + C$ , unde  $0$  semnifică vectorul nul din  $Y$  iar  $\mathbb{R}_+$  este mulțimea numerelor reale nenegative. Partea liniară a conului  $C$  este definită prin  $\ell(C) := C \cap (-C)$ . Pentru fiecare punct  $y \in Y$  și orice mulțime  $A \subseteq Y$ , notăm cu  $\mathcal{V}(y)$  mulțimea tuturor vecinătăților punctului  $y$ , iar cu  $\text{int } A$ ,  $\text{cl } A$  și  $\text{bd } A$  interiorul, aderența și respectiv frontiera lui  $A$ . Este cunoscut faptul că

$$\text{int } A \subseteq \{x \in A \mid \forall d \in Y, \exists r \in \mathbb{R}_+^* \text{ a.i. } x + [-r, r] \cdot d \subseteq A\}, \quad (1.1)$$

unde  $\mathbb{R}_+^* := \mathbb{R}_+ \setminus \{0\}$  este mulțimea numerelor reale fără zero.

Vom investiga mai multe concepte de convexitate generalizată pentru funcții vectoriale  $f : D \rightarrow Y$  în raport cu  $C$ , care extind în mod natural noțiunile clasice corespunzătoare de convexitate generalizată cunoscute pentru funcțiile scalare de tip  $\varphi : D \rightarrow \mathbb{R}$ . Pentru acest lucru, este posibil ca ocazional să introducem proprietăți suplimentare referitoare la conul  $C$ , contextul specific dictând natura acestora. Amintim că  $C$  se numește: propriu, dacă  $C \neq Y$ ; ascuțit, dacă  $\ell(C) = \{0\}$ ; solid, dacă  $\text{int } C \neq \emptyset$ ; închis, dacă  $\text{cl } C = C$ .

În cele ce urmează, vom revizui câteva proprietăți de bază ale conului convex  $C$  (a se vedea, de exemplu, cărțile lui Jahn [43] și Tammer și Weidner [82]):

$$\text{int } C = \mathbb{R}_+^* \cdot \text{int } C = C + \text{int } C = \text{cl } C + \text{int } C = C + \mathbb{R}_+^* \cdot e, \quad \forall e \in \text{int } C, \quad (1.2)$$

$$Y = \text{int } C - \mathbb{R}_+^* \cdot e, \quad \forall e \in \text{int } C, \quad (1.3)$$

$$\begin{aligned} \text{cl } C &= \mathbb{R}_+^* \cdot \text{cl } C, \\ \text{bd } C &= \mathbb{R}_+^* \cdot \text{bd } C. \end{aligned} \quad (1.4)$$

Dacă  $C$  e solid, atunci

$$\begin{aligned} \text{int } C &= \text{int}(\text{cl } C), \\ \text{cl } C &= \text{cl}(\text{int } C). \end{aligned}$$

Dacă  $C$  este propriu, atunci

$$0 \in \text{bd } C.$$

**Lemă 1.1.1.** *Fie  $C$  un con solid. Atunci, pentru orice vector  $e \in \text{int } C$  au loc următoarele egalități*

$$Y \setminus \text{cl } C = \text{bd } C - \mathbb{R}_+^* \cdot e = \text{bd } C - \text{int } C. \quad (1.5)$$

**Lemă 1.1.2.** *Fie  $C$  un con solid și fie  $e \in \text{int } C$ . Atunci, pentru orice vector  $v \in Y$  următoarele afirmații sunt echivalente:*

- 1°  $v \in \text{cl } C$ .
- 2°  $(v + \text{int } C) \cap \text{bd } C = \emptyset$ .
- 3°  $(v + \mathbb{R}_+^* \cdot e) \cap \text{bd } C = \emptyset$ .

## 1.2 Convexitate generalizată

### 1.2.1 Convexitate generalizată pentru funcții scalare

În această subsecțiune vom reaminti definiția clasică a convexității, alături de alte trei concepte cunoscute de convexitate generalizată pentru funcții scalare, răspândite pe scară largă pentru importanța lor în optimizare (a se vedea, de exemplu, Avriel *et al.* [2], Cambini și Martein [14]).

**Definiție 1.2.1.** *O funcție  $\varphi : D \rightarrow \mathbb{R}$  se numește:*

- *convexă, dacă pentru orice  $x, x' \in D$  și  $t \in (0, 1)$  avem*

$$\varphi((1-t)x + tx') \leq (1-t)\varphi(x) + t\varphi(x').$$

- *cvasiconvexă, dacă pentru orice  $x, x' \in D$  și  $t \in (0, 1)$  avem*

$$\varphi((1-t)x + tx') \leq \max \{ \varphi(x), \varphi(x') \}.$$

- *semistrict cvasiconvexă, dacă pentru orice  $x, x' \in D$  și  $t \in (0, 1)$ ,*

$$\varphi(x) \neq \varphi(x') \implies \varphi((1-t)x + tx') < \max \{ \varphi(x), \varphi(x') \}.$$

- *explicit cvasiconvexă, dacă  $\varphi$  este atât cvasiconvexă cât și semistrict cvasiconvexă.*

Următoarea propoziție reiese imediat din Definiția 1.2.1 și caracterizarea cvasiconvexității explicite dată de Popovici [63, Rem. 3.1] (vezi și Günther și Popovici [37, Prop. 2.2]).

**Propoziție 1.2.2.** *Pentru orice funcție  $\varphi : D \rightarrow \mathbb{R}$  următoarele afirmații sunt adevărate:*

a)  $\varphi$  este convexă dacă și numai dacă pentru orice  $\lambda, \lambda' \in \mathbb{R}$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$\varphi(x) \leq \lambda \text{ și } \varphi(x') \leq \lambda' \implies \varphi((1-t)x + tx') \leq (1-t)\lambda + t\lambda'.$$

b)  $\varphi$  este cvasiconvexă dacă și numai dacă pentru orice  $\lambda \in \mathbb{R}$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$\varphi(x) \leq \lambda \text{ și } \varphi(x') \leq \lambda \implies \varphi((1-t)x + tx') \leq \lambda.$$

c)  $\varphi$  este semistrict cvasiconvexă dacă și numai dacă pentru orice  $\lambda \in \mathbb{R}$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$\varphi(x) = \lambda \text{ și } \varphi(x') < \lambda \implies \varphi((1-t)x + tx') < \lambda.$$

d)  $\varphi$  este explicit cvasiconvexă dacă și numai dacă pentru orice  $\lambda \in \mathbb{R}$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$\varphi(x) \leq \lambda \text{ și } \varphi(x') < \lambda \implies \varphi((1-t)x + tx') < \lambda.$$

**Observație 1.2.3.** *Următoarele afirmații cu privire la funcții scalare sunt binecunoscute:*

- a) *Funcțiile convexe sunt explicit cvasiconvexe.*
- b) *Funcțiile semistrict cvasiconvexe și inferior semicontinue de-a lungul segmentelor (cf. Popovici [64]), sunt de asemenea explicit cvasiconvexe.*
- c) *Cvasiconvexitatea și semistrict cvasiconvexitatea nu se implică în general una pe cealaltă, așa cum arată exemplele următoare.*

În continuare, pentru  $n \in \mathbb{N}$ , vom adopta notația

$$I_n := \{1, \dots, n\}.$$

În următoarele secțiuni vom prezenta și examina concepte de convexitate generalizată pentru funcții vectoriale. Dorim să subliniem că în cazul finit-dimensional, când  $Y = \mathbb{R}^n$  ( $n \geq 2$ ), astfel de concepte se pot defini folosind componentele scalare ale funcției după cum urmează.



**Definiție 1.2.4.** O funcție  $f = (f_1, \dots, f_n) : D \rightarrow \mathbb{R}^n$  se numește convexă pe componente (cvasiconvexă, semistrict cvasiconvexă, explicit cvasiconvexă) dacă pentru orice  $i \in I_n$  componenta scalară  $f_i : D \rightarrow \mathbb{R}$  este convexă (cvasiconvexă, semistrict cvasiconvexă respectiv explicit cvasiconvexă) în sensul definiției de bază.

Următorul rezultat ilustrează două caracterizări foarte cunoscute de convexitate generalizată (a se vedea, e.g., Günther și Popovici [37, Ex. 4.7], La Torre, Popovici și Rocca [50, Cor. 8], Luc [53, Cor. 6.6]).

**Propoziție 1.2.5.** Pentru orice funcție  $f = (f_1, \dots, f_n) : D \rightarrow \mathbb{R}^n$  următoarele afirmații sunt echivalente:

1°  $f$  este convexă pe componente (cvasiconvexă, explicit cvasiconvexă).

2° Oricare ar fi numerele reale  $a_1, \dots, a_n \in \mathbb{R}$ , funcția

$$\max\{f_i(\cdot) - a_i \mid i \in I_n\} : D \rightarrow \mathbb{R}$$

este convexă (cvasiconvexă respectiv explicit cvasiconvexă).

## 1.2.2 Funcții $C$ -convexe, $C$ -cvasiconvexe și explicit $C$ -cvasiconvexe

În cele ce urmează vom reaminti trei concepte importante de convexitate generalizată pentru funcții vectoriale. Ele sunt binecunoscute în domeniul optimizării vectoriale și alte domenii asociate, așa cum este evidențiat în lucrări precum Bagdasar și Popovici [3, 4], Luc [53], Popovici [63, 64], și referințele incluse în acestea.

**Definiție 1.2.6.** O funcție  $f : D \rightarrow Y$  se numește

- $C$ -convexă, dacă pentru orice  $x, x' \in D$  și  $t \in (0, 1)$  avem

$$f((1-t)x + tx') \in (1-t)f(x) + tf(x') - C, \text{ i.e.,}$$

pentru orice  $y, y' \in Y$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$f(x) \in y - C \text{ și } f(x') \in y' - C \implies f((1-t)x + tx') \in (1-t)y + ty' - C.$$

- $C$ -cvasiconvexă, dacă pentru orice  $y \in Y$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$f(x) \in y - C \text{ și } f(x') \in y - C \implies f((1-t)x + tx') \in y - C.$$

- *explicit  $C$ -cvasiconvexă, dacă pentru orice  $y \in Y$ ,  $x, x' \in D$  și  $t \in (0, 1)$ ,*

$$f(x) \in y - C \text{ și } f(x') \in y - \text{int } C \implies f((1-t)x + tx') \in y - \text{int } C.$$

Următorul rezultat prezintă trei caracterizări foarte cunoscute ale funcțiilor convex generalizate (a se vedea, de exemplu, Luc [53] și Popovici [63]).

**Propoziție 1.2.7.** *Pentru orice funcție  $f : D \rightarrow Y$  au loc următoarele afirmații:*

- 1°  *$f$  este  $C$ -convexă ddacă epigraful său*

$$\text{epi}_C(f) = \{(x, y) \in D \times Y \mid y \in f(x) + C\}$$

*este o mulțime convexă.*

- 2°  *$f$  este  $C$ -cvasiconvexă ddacă pentru orice punct  $y \in Y$ , mulțimea de nivel inferioară  $f^{-1}(y - C)$  este convexă.*

- 3°  *$f$  este explicit  $C$ -cvasiconvexă ddacă pentru orice puncte  $y \in Y$ ,  $x \in f^{-1}(y - C)$ ,  $x' \in f^{-1}(y - \text{int } C)$  și  $t \in (0, 1)$  avem apartenența*

$$(1-t)x + tx' \in f^{-1}(y - \text{int } C).$$

### 1.2.3 Funcții semistrict $C$ -cvasiconvexe

În cadrul acestei subsecțiunii introducem, în următoarea definiție, noul nostru concept de semistrict cvasiconvexitate și stabilim legătura dintre această noțiune și alte concepte cunoscute de convexitate generalizată din literatură. În acest scop considerăm  $C \subseteq Y$  un con convex solid. În aceste condiții, se cunoaște faptul că  $C - C = Y$ ,  $\text{bd } C \neq \emptyset$  și  $C \setminus (-C) \neq \emptyset$ .

**Definiție 1.2.8.** *Spunem că funcția  $f : D \rightarrow Y$  este semistrict  $C$ -cvasiconvexă dacă pentru orice  $y \in Y$ ,  $x, x' \in D$  și  $t \in (0, 1)$  avem*

$$f(x) \in y - \text{bd } C \text{ și } f(x') \in y - \text{int } C \implies f((1-t)x + tx') \in y - \text{int } C.$$

**Observație 1.2.9.** *Asemănător cu caracterizarea funcțiilor explicit  $C$ -cvasiconvexe dată de Propoziția 1.2.7 (3°), se poate demonstra ușor că o funcție  $f : D \rightarrow Y$  este semistrict  $C$ -cvasiconvexă dacă și numai dacă pentru orice puncte  $y \in Y$ ,  $x \in f^{-1}(y - \text{bd } C)$ ,  $x' \in f^{-1}(y - \text{int } C)$  și  $t \in (0, 1)$  avem  $(1-t)x + tx' \in f^{-1}(y - \text{int } C)$ .*

**Observație 1.2.10.** Fie  $C' \subseteq Y$  un con convex astfel încât  $\text{int } C' = \text{int } C$ . Cum  $C$  este solid, rezultă că  $\text{cl } C' = \text{cl}(\text{int } C') = \text{cl}(\text{int } C) = \text{cl } C$ , deci  $\text{bd } C' = \text{bd } C$ . Prin urmare,  $f$  este semistrict  $C'$ -cvasiconvexă dacă și numai dacă  $f$  este semistrict  $C$ -cvasiconvexă.

În cele ce urmează vom prezenta câteva relații între semistrict  $C$ -cvasiconvexitate și alte concepte cunoscute de convexitate generalizată.

**Lemă 1.2.11.** Dacă  $f : D \rightarrow Y$  este atât  $C$ -cvasiconvexă cât și semistrict  $C$ -cvasiconvexă, atunci  $f$  este explicit  $C$ -quasiconvexă.

**Lemă 1.2.12.** Dacă  $C$  este închis, atunci orice funcție  $f : D \rightarrow Y$  explicit  $C$ -quasiconvexă este atât  $C$ -cvasiconvexă cât și semistrict  $C$ -cvasiconvexă.

Următorul rezultate oferă o nouă caracterizare a explicit  $C$ -cvasiconvexității.

**Teoremă 1.2.13.** Dacă  $C$  este închis, atunci pentru orice funcție  $f : D \rightarrow Y$  următoarele afirmații sunt echivalente:

1°  $f$  este explicit  $C$ -cvasiconvexă.

2°  $f$  este atât  $C$ -cvasiconvexă cât și semistrict  $C$ -cvasiconvexă.

Fie  $f : D \rightarrow Y$  o funcție. Introducem următoarea notație

$$\Theta_f(x, x', y) = \{t \in [0, 1] \mid (1-t)x + tx' \notin f^{-1}(y - C)\}$$

pentru orice puncte  $x, x' \in D$  și  $y \in Y$ .

**Observație 1.2.14.** Fie  $f : D \rightarrow Y$  o funcție și fie  $y \in Y$ . Dacă  $x, x' \in f^{-1}(y - C)$ , atunci

$$\Theta_f(x, x', y) = \{t \in (0, 1) \mid (1-t)x + tx' \notin f^{-1}(y - C)\}.$$

**Observație 1.2.15.** Pentru orice funcție  $f : D \rightarrow Y$ , următoarele afirmații sunt echivalente:

1°  $f$  este  $C$ -cvasiconvexă.

2° Pentru orice  $y \in Y$  și  $x, x' \in f^{-1}(y - C)$  avem  $\Theta_f(x, x', y) = \emptyset$ .

**Lemă 1.2.16.** Fie  $C$  închis și  $f : D \rightarrow Y$  o funcție semistrict  $C$ -cvasiconvexă. Atunci pentru orice  $y \in Y$  și  $x, x' \in f^{-1}(y - C)$ , mulțimea  $\Theta_f(x, x', y)$  este fie un singleton fie vidă.

**Definiție 1.2.17.** Se spune că funcția  $f : D \rightarrow Y$  este inferior  $C$ -semicontinuuă de-a lungul segmentelor dacă pentru orice puncte  $x, x' \in D$  funcția

$$t \in [0, 1] \mapsto f((1-t)x + tx') \in Y$$

are  $C$ -mulțimile de nivel inferioare, i.e.,

$$\{t \in [0, 1] \mid f((1-t)x + tx') \in y - C\} \quad (1.6)$$

închise pentru orice  $y \in Y$ .

**Observație 1.2.18.** Fie  $f : D \rightarrow Y$  o funcție și fie  $x, x' \in D$ . Pentru orice  $y \in Y$  mulțimea de nivel (1.6) admite reprezentarea

$$\{t \in [0, 1] \mid f((1-t)x + tx') \in y - C\} = [0, 1] \setminus \Theta_f(x, x', y).$$

**Teoremă 1.2.19.** Fie conul  $C$  închis. Dacă funcția  $f : D \rightarrow Y$  este semistrict  $C$ -cvasiconvexă și inferior  $C$ -semicontinuuă de-a lungul segmentelor, atunci  $f$  este  $C$ -cvasiconvexă.

Încheiem această secțiune stabilind un rezultat de legătură între conceptul nostru de semistrict  $C$ -cvasiconvexitate și un alt concept de convexitate generalizată, introdus de Flores-Bazán în [23] (vezi de asemenea și Flores-Bazán și Vera [25], și Flores-Bazán și Hernández [24]).

**Definiție 1.2.20.** Fie  $P \subseteq Y$  o mulțime nevidă. Spunem că funcția  $f : D \rightarrow Y$  este semistrict  $\langle P \rangle$ -cvasiconvexă în sens Flores-Bazán dacă pentru orice  $x, x' \in D$  și  $t \in (0, 1)$ ,

$$f(x') \in f(x) - P \implies f((1-t)x + tx') \in f(x) - P.$$

**Teoremă 1.2.21.** Fie  $C$  un con convex închis și fie  $P \in \{\text{int } C, C \setminus (-C), Y \setminus (-C)\}$ . Atunci orice funcție semistrict  $C$ -cvasiconvexă  $f : D \rightarrow Y$  este semistrict  $\langle P \rangle$ -cvasiconvexă în sens Flores-Bazán.

### 1.3 Caracterizarea funcțiilor semistrict și explicit $C$ -cvasiconvexe cu ajutorul funcțiilor neliniare de scalarizare

Ultima secțiune conține rezultatul nostru central care caracterizează funcțiile semistrict  $C$ -cvasiconvexe prin intermediul funcțiilor de scalarizare neliniare.

De asemenea, prezentăm câteva rezultate cunoscute referitoare la caracterizarea funcțiilor vectoriale  $C$ -convexe (respectiv, semistrict  $\langle \text{int}, C \rangle$ -cvasiconvexe, semistrict  $\langle C \rangle$ -cvasiconvexe, explicit  $C$ -cvasiconvexe) prin intermediul funcțiilor de scalarizare neliniare  $\sigma_a$ .

Pentru acest lucru fie  $C \subseteq Y$  un con propriu convex închis și solid. Pentru un vector  $e \in \text{int } C$ , notăm cu  $\sigma : Y \rightarrow \mathbb{R}$  funcția de scalarizare neliniară în sens Gerstewitz (Tammer) [29], definită pentru orice  $y \in Y$  prin

$$\sigma(y) := \min\{s \in \mathbb{R} \mid y \in se - C\}.$$

De asemenea pentru un punct  $a \in Y$ , se poate considera funcția  $\sigma_a : Y \rightarrow \mathbb{R}$ , definită pentru orice  $y \in Y$  prin

$$\sigma_a(y) = \sigma(y - a),$$

unde funcția inițială  $\sigma$  se notează de regulă cu  $\sigma_0$ . Aceste funcții au fost studiate și folosite extensiv atât în optimizarea vectorială cât și multivocă și sunt de asemenea cunoscute în domeniul matematicii economice (vezi, e.g., Göpfert *et al.* [32], Khan, Tammer și Zălinescu [45], Luc [53], Tammer și Weidner [30], Tammer și Zălinescu [83] și lucrările citate de aceștia). Conform lui Göpfert *et al.* [32, Th. 2.3.1], au loc următoarele proprietăți:

$$\{y \in Y \mid \sigma(y) \leq 0\} = -C, \quad (1.7)$$

$$\{y \in Y \mid \sigma(y) = 0\} = -\text{bd } C, \quad (1.8)$$

$$\{y \in Y \mid \sigma(y) < 0\} = -\text{int } C. \quad (1.9)$$

mai mult, pentru orice  $\lambda \in \mathbb{R}$  și  $y \in Y$  avem că

$$\sigma(y - \lambda e) = \sigma(y) - \lambda. \quad (1.10)$$

O caracterizare a funcțiilor vectoriale explicit  $C$ -cvasiconvexe prin intermediul funcțiilor de scalarizare neliniare  $\sigma_a$  este prezentată în următoarea teoremă.

**Teoremă 1.3.1.** *O funcție  $f : D \rightarrow Y$  este explicit  $C$ -cvasiconvexă dacă și numai dacă pentru orice  $a \in Y$ , funcția  $\sigma_a \circ f : D \rightarrow \mathbb{R}$  este explicit cvasiconvexă.*

**Corolar 1.3.2.** *Dacă  $f_1, \dots, f_n$  sunt inferior semicontinue de-a lungul segmentelor, atunci următoarele afirmații sunt echivalente:*

- 1°  $f$  este semistrict  $\mathbb{R}_+^n$ -cvasiconvexă.
- 2°  $f$  este explicit  $\mathbb{R}_+^n$ -cvasiconvexă.
- 3°  $f$  este explicit cvasiconvexă pe componente.
- 4°  $f$  este semistrict cvasiconvexă pe componente.

---

## Capitolul 2

# Proprietăți ale funcțiilor fracționare

---

Proprietatea de conservare sau păstrare a convexității mulțimilor prin imagini directe și inverse este foarte importantă în optimizare, în special în optimizarea convexă, deoarece simplifică formulările problemelor, permite utilizarea eficientă a algoritmilor și joacă un rol fundamental în teoria dualității convexe.

Această proprietate este strâns legată de funcțiile convexe. Cu toate acestea, alte clase de funcții, cum ar fi câtul dintre o funcție convexă și una concavă (în special o funcție pătratică și una afină, sau două funcții afine), s-au dovedit, de asemenea, semnificative în optimizarea scalară. Lucrările cercetătorilor precum Cambini și Martein [14], Göpfert *et al.* [32], Schaible [73], și Stancu-Minasian [79] au explorat extensiv această zonă. În timp ce optimizarea multivocă rămâne un domeniu vital de studiu al teoriei generale a optimizării (vezi, de exemplu, Khan, Tammer și Zălinescu [45]), există o nevoie reală în studiul proprietăților funcțiilor de tip fracționar. Contribuții remarcabile în această direcție includ lucrări precum cea a lui Bhatia și Mehra [8], Das și Nahak [18] împreună cu alte referințe citate de aceștia.

În acest capitol, oferim o serie de rezultate de păstrare a convexității mulțimilor pentru două clase speciale de funcții multivoce de tip fracționar.

Capitolul este împărțit în patru secțiuni. **Secțiunea 2.1** este dedicată introducerii noțiunilor și rezultatelor generale de analiză multivocă și convexă.

**Secțiunea 2.2** investighează conceptul de funcție multivocă afină în sens Tan [84] și demonstrează că inversa unei astfel de funcții este, de asemenea, afină—o distincție față de alte concepte de funcții affine multivoce, după cum este ilustrat de Kuroiwa *et al.* [48, Ex. 2]. Mai mult, în cadrul acestei secțiuni se extind o serie de rezultatele clasice ale lui Rothblum [70] din spațiile euclidiene finite-dimensionale la spații liniare reale.

În **Secțiunea 2.3**, explorăm un concept alternativ de afinitate pentru funcții multivoce, introdus în literatură de Gorokhovich [33, 34] și furnizăm o

serie de rezultate care vor avea o importanță semnificativă pentru secțiunea următoare.

Ultima **Secțiune 2.4** prezintă mai multe rezultate de păstrare a convexității pentru funcții multivoce.

Rezultatele prezentate în această parte a tezei au fost incluse în lucrările Orzan și Popovici [60, 61] și Orzan [59].

## 2.1 Preliminarii

În cadrul primei secțiuni din acest capitol vom acoperi câteva definiții și rezultate de bază de analiză multivocă și convexă, care vor fi utile pe măsură ce vom avansa. În acest scop vom considera  $X$  și  $Y$  două spații liniare reale. Ca de obicei în analiza multivocă (vezi, e.g., Aubin și Frankowska [1]), pentru orice multifuncție  $F : X \rightarrow \mathcal{P}(Y)$  notăm cu

$$\text{dom } F = \{x \in X \mid F(x) \neq \emptyset\}$$

domeniul lui  $F$ . Se spune că  $F$  este proprie dacă  $\text{dom } F \neq \emptyset$ . Imaginea (directă) a mulțimii  $A \subseteq X$  prin  $F$  se definește prin

$$F(A) = \bigcup_{x \in A} F(x).$$

Există mai multe moduri de a defini imaginea inversă a unei mulțimi  $B \subseteq Y$  printr-o multifuncție  $F$ , două dintre ele fiind cel mai des folosite în analiza multivocă (Aubin și Frankowska [1]) fiind:

$$F^{-1}(B) = \{x \in X \mid F(x) \cap B \neq \emptyset\}, \quad (1.11)$$

$$F^{+1}(B) = \{x \in X \mid F(x) \subseteq B\}. \quad (1.12)$$

Mulțimea  $F^{-1}(B)$  se numește imaginea inversă a lui  $B$  prin  $F$ , iar  $F^{+1}(B)$  se numește nucleul lui  $B$  prin  $F$  (cunoscute de asemenea sub denumirea de imaginea inversă inferioară respectiv imaginea inversă superioară a mulțimii  $B$  prin  $F$ ). Legătura dintre cele două este dată de relația (vezi, e.g., Kassay și Rădulescu [44, Sec. 1.3])

$$F^{+1}(B) = X \setminus F^{-1}(Y \setminus B). \quad (1.13)$$

## 2.2 Multifuncții afine în sens Tan

Generalizarea conceptului de afinitate pentru funcțiile multivoce este abordată în diverse moduri în literatură. Exemple remarcabile în acest sens

includ lucrările lui Deutsch și Singer [19], Nikodem și Popa [57], Tan [84], Gorokhovich [33], Gorokhovich și Zabreiko [34] și referințele citate de aceștia. Dintre aceste abordări, cea dezvoltată de Tan [84], va servi ca principal instrument în această secțiune și este prezentată în cele ce urmează.

**Definiție 2.2.1.** O funcție multivocă  $G : X \rightarrow \mathcal{P}(Y)$  se numește afină (în sens Tan) dacă

$$G((1-t)x^1 + tx^2) = (1-t)G(x^1) + tG(x^2) \quad (1.14)$$

pentru orice  $x_1, x_2 \in \text{dom } G$  și  $t \in \mathbb{R}$ .

**Propoziție 2.2.2.** Pentru orice funcție multivocă  $G : X \rightarrow \mathcal{P}(Y)$  următoarele afirmații sunt echivalente:

1°  $G$  este afină.

2° Pentru orice  $x^1, x^2 \in \text{dom } G$  și  $t \in \mathbb{R}$  avem că

$$(1-t)G(x^1) + tG(x^2) \subseteq G((1-t)x^1 + tx^2).$$

**Teoremă 2.2.3.** Fie  $G : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă afină. Atunci inversa lui  $G$ , i.e., funcția multivocă  $G^{-1} : Y \rightarrow \mathcal{P}(X)$ , este afină.

**Corolar 2.2.4.** Dacă  $g : E \rightarrow Y$  este o funcție afină vectorială, definită pe o mulțime nevidă și afină  $E \subseteq X$ , atunci funcția multivocă  $g^{-1} : Y \rightarrow \mathcal{P}(X)$  este afină.

## 2.2.1 Funcții vectoriale fracționar afine

Începem această subsecțiune prin extinderea noțiunii de funcție vectorială fracționar afină, introdusă inițial de Rothblum [70] în spațiile euclidiene finite-dimensionale, la cadrul spațiilor liniare reale.

**Definiție 2.2.5.** O funcție vectorială  $f : D \rightarrow Y$ , definită pe o mulțime nevidă și convexă  $D \subseteq X$ , se numește fracționar afină dacă există o funcție o funcție afină vectorială  $g : X \rightarrow Y$  și o funcție afină scalară  $h : X \rightarrow \mathbb{R}$ , astfel încât

$$D \subseteq \{x \in X \mid h(x) > 0\}$$

și

$$f(x) = \frac{g(x)}{h(x)}, \quad \forall x \in D.$$



Următoarele propoziții extind în cadrul spațiilor liniare reale rezultatele obținute în  $\mathbb{R}^n$  de către Rothblum (vezi [70, Props. 1, 2 și 3]). Demonstrațiile lor sunt omise, deoarece urmează același raționament ca în Rothblum [70].

**Propoziție 2.2.6.** *Dacă  $f : D \rightarrow Y$  este o funcție vectorială definită pe o mulțime nevidă și convexă  $D \subseteq X$ , atunci următoarele afirmații sunt echivalente:*

1°  $\text{conv } f(S) \subseteq f(\text{conv } S)$  pentru orice mulțime  $S \subseteq D$ .

2° mulțimea  $f(A)$  este convexă pentru orice mulțime  $A \subseteq D$ .

**Propoziție 2.2.7.** *Dacă  $f : D \rightarrow Y$  este o funcție vectorială definită pe o mulțime nevidă și convexă  $D \subseteq X$ , atunci următoarele afirmații sunt echivalente:*

1°  $f(\text{conv } S) \subseteq \text{conv } f(S)$  pentru orice mulțime  $S \subseteq D$ .

2° mulțimea  $f^{-1}(B)$  este convexă pentru orice mulțime convexă  $B \subseteq Y$ .

**Propoziție 2.2.8.** *Fie  $D \subseteq X$  o mulțime nevidă și convexă. Dacă  $f : D \rightarrow Y$  este o funcție vectorială fracționar afină, atunci*

$$\text{conv } f(S) = f(\text{conv } S) \text{ for every set } S \subseteq D.$$

## 2.2.2 Funcții multivoce fracționar afine

În această subsecțiune introducem o nouă clasă de funcții multivoce fracționar afine ce are la bază clasa propusă de Orzan în [59, Def. 3.3]. Vom arăta că aceste funcții de tip fracționar păstrează convexitatea mulțimilor prin imagini directe și inverse, o proprietate care, după cum am menționat deja, este semnificativă în optimizare, în special în contextul optimizării convexe.

**Definiție 2.2.9.** Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă cu domeniul o mulțime nevidă și convexă. Spunem că  $F$  este fracționar afină (în sens Tan) dacă există o funcție multivocă afină și proprie  $G : X \rightarrow \mathcal{P}(Y)$  și o funcție afină scalară  $h : X \rightarrow \mathbb{R}$ , nenulă, astfel încât

$$\text{dom } F \subseteq \{x \in X \mid h(x) > 0\} \cap \text{dom } G$$

și

$$F(x) = \begin{cases} \frac{G(x)}{h(x)} & \text{dacă } x \in \text{dom } F \\ \emptyset & \text{dacă } x \in X \setminus \text{dom } F. \end{cases} \quad (1.15)$$

**Teoremă 2.2.10.** Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă fracționară afină de forma (1.15). Atunci există o funcție fracționară afină vectorială  $f : \text{dom } F \rightarrow Y$  și un spațiu liniar  $M \subseteq Y$ , astfel încât

$$F(x) = \begin{cases} f(x) + M & \text{dacă } x \in \text{dom } F \\ \emptyset & \text{dacă } x \in X \setminus \text{dom } F. \end{cases} \quad (1.16)$$

**Teoremă 2.2.11.** Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă de forma (1.16), unde  $\text{dom } F \subseteq X$  și  $M \subseteq Y$  sunt mulțimi nevide și convexe, iar  $f : \text{dom } F \rightarrow Y$  o funcție vectorială ce păstrează convexitatea mulțimilor prin imagini directe. Atunci, pentru orice mulțime convexă  $A \subseteq X$ , mulțimea  $F(A)$  este convexă.

**Teoremă 2.2.12.** Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă de forma (1.16), unde  $\text{dom } F \subseteq X$  și  $M \subseteq Y$  sunt mulțimi nevide și convexe, iar  $f : \text{dom } F \rightarrow Y$  o funcție vectorială ce păstrează convexitatea mulțimilor prin imagini inverse. Atunci, pentru orice mulțime convexă  $B \subseteq Y$ , mulțimile  $F^{-1}(B)$  și  $F^{-1}(B) \cap \text{dom } F$  sunt convexe.

**Corolar 2.2.13.** Dacă  $F : X \rightarrow \mathcal{P}(Y)$  este o funcție multivocă fracționară afină de forma (1.15), atunci următoarele afirmații sunt adevărate:

- 1°  $F$  păstrează convexitatea mulțimilor prin imagini directe.
- 2°  $F$  păstrează convexitatea mulțimilor prin imagini inverse inferioare.
- 3°  $F$  păstrează convexitatea mulțimilor prin imagini inverse superioare în sens Berge.

## 2.3 Funcții multivoce afine în sens Gorokhovich

În cadrul acestei secțiuni vom investiga un alt concept de afinitate pentru funcții multivoce, introdus de V. Gorokhovich [33], care este mai general decât conceptul de afinitate dat de Tan.

**Definiție 2.3.1.** O funcție multivocă  $G : X \rightarrow \mathcal{P}(Y)$  se numește  
(i) *convexă* dacă

$$(1 - t)G(x^1) + tG(x^2) \subseteq G((1 - t)x^1 + tx^2)$$

pentru orice  $x^1, x^2 \in \text{dom } G$  și  $t \in [0, 1]$ ;

(ii) *concavă* dacă  $\text{dom } G$  este o mulțime convexă din  $X$  și

$$G((1-t)x^1 + tx^2) \subseteq (1-t)G(x^1) + tG(x^2)$$

pentru orice  $x^1, x^2 \in \text{dom } G$  și  $t \in [0, 1]$ ;

(iii) *afină* (în sens Gorokhovich) dacă

$$G((1-t)x^1 + tx^2) = (1-t)G(x^1) + tG(x^2)$$

pentru orice  $x^1, x^2 \in \text{dom } G$  și  $t \in [0, 1]$ .

Fie  $K \subseteq X$  un con.

**Definiție 2.3.2** (Nikodem [56]). Fie  $F : X \rightarrow \mathcal{P}_0(Y)$  o funcție multivocă. Atunci  $F$  se numește *K-vasiconcavă* dacă satisface condiția

$$F(x^1) \subseteq A + K \quad \text{și} \quad F(x^2) \subseteq A + K \Rightarrow F((1-t)x^1 + tx^2) \subseteq A + K$$

pentru orice mulțime convexă  $A \subseteq Y$ ,  $x^1, x^2 \in X$  și  $t \in [0, 1]$ .

**Observație 2.3.3.** Dacă  $K = \{0_X\}$ , atunci  $F$  este *vasiconcavă*.

Următorul rezultat va fi folositor pe parcurs. Pentru oricare două numere reale  $a, b \in \mathbb{R}$ ,  $a, b > 0$  considerăm funcția fracționar afină  $\sigma_{a,b} : [0, 1] \rightarrow [0, 1]$  definită prin

$$\sigma_{a,b}(t) = \frac{tb}{(1-t)a + tb}. \quad (1.17)$$

**Observație 2.3.4.** Se verifică ușor faptul că  $\sigma_{a,b}$  e bine definită și are următoarele proprietăți:

- 1°  $\sigma_{a,b}$  este strict crescătoare;
- 2°  $\sigma_{a,b}$  este convexă pentru  $a > b$ ,  $\sigma_{a,b}$  este concavă dacă  $a < b$  și  $\sigma_{a,b}(t) = t$  pentru orice  $t \in [0, 1]$  dacă  $a = b$ ;
- 3°  $\sigma_{a,b}$  este bijectivă și inversa sa  $\sigma_{a,b}^{-1}$  este funcția  $\sigma_{b,a}$ .

### 2.3.1 Funcții fracționar affine multivoce

În următoarea etapă vom explora proprietăți de păstrare a convexității folosind conceptul de afinitate pentru funcții multivoce specific lui Gorokhovich. Acest lucru va facilita munca noastră și, în același timp, va pregăti terenul pentru rezultatele viitoare.

**Definiție 2.3.5.** Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă cu  $\text{dom } F$  o mulțime convexă. Spunem că  $F$  este *fracționară afină* (în sens Gorokhovich) dacă există o funcție multivocă afină și proprie  $G : X \rightarrow \mathcal{P}(Y)$  și o funcție afină scalară  $h : X \rightarrow \mathbb{R}$ , nenulă, astfel încât

$$\text{dom } F \subseteq \{x \in X \mid h(x) > 0\} \cap \text{dom } G$$

și

$$F(x) = \begin{cases} \frac{G(x)}{h(x)} & \text{dacă } x \in \text{dom } F \\ \emptyset & \text{dacă } x \in X \setminus \text{dom } F. \end{cases}$$

**Lemă 2.3.6.** Fie  $F$  o funcție multivocă fracționară în care numărătorul este o multifuncție  $G$  iar numitorul este o funcție afină pozitivă  $h$ . Atunci următoarele afirmații sunt adevărate:

1° Dacă  $G$  este convexă, atunci

$$(1 - \sigma_{h(x^1), h(x^2)}(t))F(x^1) + \sigma_{h(x^1), h(x^2)}(t)F(x^2) \subseteq F((1 - t)x^1 + tx^2)$$

pentru orice  $x^1, x^2 \in \text{dom } F$  și  $t \in [0, 1]$ ;

2° Dacă  $G$  este concavă, atunci

$$F((1 - t)x^1 + tx^2) \subseteq (1 - \sigma_{h(x^1), h(x^2)}(t))F(x^1) + \sigma_{h(x^1), h(x^2)}(t)F(x^2)$$

pentru orice  $x^1, x^2 \in \text{dom } F$  și  $t \in [0, 1]$ ;

3° Dacă  $G$  este afină, atunci

$$F((1 - t)x^1 + tx^2) = (1 - \sigma_{h(x^1), h(x^2)}(t))F(x^1) + \sigma_{h(x^1), h(x^2)}(t)F(x^2)$$

pentru orice  $x^1, x^2 \in \text{dom } F$  și  $t \in [0, 1]$ .

**Propoziție 2.3.7.** Fie  $F$  o funcție multivocă fracționară în care numărătorul este o multifuncție convexă  $G$  iar numitorul este o funcție afină pozitivă  $h$ . Atunci

1° pentru orice  $x \in X$ , mulțimea  $F(x)$  este convexă;

2° pentru orice  $y \in Y$ , mulțimea  $F^{-1}(y)$  este convexă.

## 2.4 Proprietăți de păstrare a convexității

Încheiem acest capitol printr-o secțiune compusă din două părți. În prima subsecțiune furnizăm câteva rezultate de păstrare a convexității pentru funcții multivoce generale iar, în cea de-a doua subsecțiune, generalizăm unele dintre rezultatele obținute în secțiunile anterioare folosind conceptul de afinitate pentru funcții multivoce introdus de Gorokhovich.

### 2.4.1 Funcții multivoce generale

**Propoziție 2.4.1.** *Pentru orice funcție multivocă  $F : X \rightarrow \mathcal{P}(Y)$ , următoarele afirmații sunt echivalente:*

- 1°  $\text{conv } F(A) \subseteq F(\text{conv } A)$  pentru orice mulțime  $A \subseteq X$ .
- 2° Pentru orice mulțime convexă  $C \subseteq X$ , mulțimea  $F(C)$  este convexă.
- 3°  $\text{conv } F(\{x^1, x^2\}) \subseteq F(\text{conv } \{x^1, x^2\})$  pentru orice  $x^1, x^2 \in X$ .
- 4°  $\text{conv } F(\{x^1, x^2\}) \subseteq F(\text{conv } \{x^1, x^2\})$  pentru orice  $x^1, x^2 \in \text{dom } F$ .

**Corolar 2.4.2.** *Pentru orice funcție multivocă  $F : X \rightarrow \mathcal{P}(Y)$ , următoarele afirmații sunt echivalente:*

- 1°  $\text{conv } F^{-1}(A) \subseteq F^{-1}(\text{conv } A)$  pentru orice mulțime  $A \subseteq Y$ .
- 2° Pentru orice mulțime convexă  $C \subseteq Y$ , mulțimea  $F^{-1}(C)$  este convexă, i.e.,  $F$  este cvasiconvexă în sens Nikodem.
- 3°  $\text{conv } F^{-1}(\{y^1, y^2\}) \subseteq F^{-1}(\text{conv } \{y^1, y^2\})$  pentru orice  $y^1, y^2 \in Y$ .
- 4°  $\text{conv } F^{-1}(\{y^1, y^2\}) \subseteq F^{-1}(\text{conv } \{y^1, y^2\})$  pentru orice puncte  $y^1, y^2$  din  $\text{dom } F^{-1}$ .

**Propoziție 2.4.3.** *Pentru orice funcție multivocă  $F : X \rightarrow \mathcal{P}(Y)$  cu  $\text{dom } F$  convexă următoarele afirmații sunt echivalente:*

- 1°  $F(\text{conv } A) \subseteq \text{conv } F(A)$  pentru orice mulțime  $A \subseteq \text{dom } F$ .
- 2° Pentru orice mulțime convexă  $C \subseteq Y$ , mulțimea  $F^{-1}(C) \cap \text{dom } F$  este convexă.
- 3°  $F(\text{conv } \{x^1, x^2\}) \subseteq \text{conv } F(\{x^1, x^2\})$  pentru orice  $x^1, x^2 \in \text{dom } F$ .

## 2.4.2 Funcții multivoce fracționar afine

**Teoremă 2.4.4.** *Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă fracționară în care numărătorul este o multifuncție convexă iar numitorul este o funcție afină pozitivă. Atunci pentru orice mulțime convexă  $C \subseteq X$ , mulțimea  $F(C)$  este convexă.*

**Corolar 2.4.5.** *Dacă  $F : X \rightarrow \mathcal{P}(Y)$  este o funcție multivocă fracționar afină ca în Definiția 2.3.5, atunci pentru orice mulțime convexă  $C \subseteq X$ , mulțimea  $F(C)$  este convexă.*

**Teoremă 2.4.6.** *Fie  $F : X \rightarrow \mathcal{P}(Y)$  este o funcție multivocă fracționar afină. Atunci pentru orice mulțime convexă  $C$  din  $Y$ , mulțimea  $F^{+1}(C) \cap \text{dom } F$  este convexă.*

**Teoremă 2.4.7.** *Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă fracționară în care numărătorul este o multifuncție concavă iar numitorul este o funcție afină pozitivă, cu domeniul  $\text{dom } F \subseteq X$  nevid și convex. Atunci pentru orice mulțime convexă  $C \subseteq Y$ , mulțimea  $F^{-1}(C)$  este convexă.*

**Corolar 2.4.8.** *Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă fracționar afină. Atunci pentru orice mulțime convexă  $B \in \mathcal{P}(Y)$ , mulțimea  $F^{-1}(B)$  este convexă.*

**Corolar 2.4.9.** *Fie  $F : X \rightarrow \mathcal{P}(Y)$  o funcție multivocă afină. Atunci pentru orice mulțime convexă  $B \in \mathcal{P}(Y)$ , mulțimea  $F^{-1}(B)$  este convexă.*

---

## Capitolul 3

# Algoritmi de aproximare de tip Dinkelbach pentru probleme fracționare

---

Problemele de optimizare fracționară au atras o atenție semnificativă cercetătorilor datorită relevanței lor în modelarea diferitelor procese din lumea reală. Numeroși autori au dedicat mult timp studierii acestui subiect, cum ar fi Avriel et al. [2], Cambini și Martein [14], Stancu-Minasian [79], Elbenani și Ferland [21], precum și referințele citate de aceștia.

Exemple de probleme de optimizare fracționară pot fi identificate și în matematică în mai multe publicații, printre care menționăm lucrările lui Crouzeix [15, 16], Hadjisavvas [26], Schaible [71, 72], Rodenas [69], Shi [77], Boț et al. [10, 11], Tammer [81]. În acest capitol al tezei prezentăm câteva variante aproximative ale algoritmului clasic al lui Dinkelbach pentru problemele de optimizare fracționară în spații Banach.

Capitolul este compus din cinci secțiuni. Prima dintre ele, **Secțiunea 3.1**, introduce cadrul nostru general și algoritmul original al lui Dinkelbach.

**Secțiunea 3.2** prezintă cazul în care, la fiecare pas al algoritmului, punctul generat poate fi determinat aproximativ, cu o eroare dată  $\varepsilon > 0$ .

În **Secțiunea 3.3** prezentăm o altă variantă a algoritmului lui Dinkelbach în care eroarea converge către zero și arătăm că, sub aceeași condiție de compacitate de tip Palais-Smale, algoritmul este convergent către perechea  $(\lambda^*, \tilde{x})$ , cu alte cuvinte, soluția problemei noastre de optimizare fracționară.

**Secțiunea 3.4** propune algoritmul de aproximare Dinkelbach-Ekeland.

În cele din urmă, ultima **Secțiune 3.5** oferă condiții suficiente care fac posibilă îndeplinirea condiției Palais-Smale și oferă rezultatul nostru final referitor la convergența algoritmului Dinkelbach-Ekeland.

Rezultatele prezentate în această parte a tezei au fost incluse în lucrarea Orzan și Precup [62].

### 3.1 Probleme de optimizare fracționară și algoritmul lui Dinkelbach

Problema standard de optimizare fracționară poate fi exprimată în forma sa generală prin

$$\frac{A(x)}{B(x)} \longrightarrow \min_{x \in D},$$

unde  $A$  și  $B$  sunt două funcționale definite pe o mulțime nevidă  $D$  iar  $B(x) \neq 0$  pentru orice  $x \in D$ . Rezolvarea acestei probleme se reduce la determinarea unei perechi  $(\lambda^*, x^*)$ , unde  $\lambda^*$  este valoarea minimă a funcției  $A/B$  și  $x^*$  este punctul de minim, i.e.,

$$\lambda^* = \frac{A(x^*)}{B(x^*)} = \min_D \frac{A}{B}.$$

Pe lângă metodele directe de minimizare, adesea folosite la rezolvarea acestei probleme, există și tehnici specifice care transformă problema fracționară într-o problemă de optimizare ce implică o funcțională non-fracționară. Un astfel de procedeu, introdus de Dinkelbach [20], se bazează pe problema parametrică

$$A(x) - \lambda B(x) \longrightarrow \min_{x \in D}.$$

Această metodă constă în generarea unui șir  $(\lambda_k)$  de valori care în cele din urmă vor converge la minimumul raportului  $A/B$ . Alături de acest șir, se generează concomitent un alt șir  $(x_k)$  care va converge către punctul de minim dorit. Pentru a îmbunătăți înțelegerea acestei metode, furnizăm o scurtă prezentare a algoritmului lui Dinkelbach și conturăm principalele etape ale demonstrației convergenței sale. Presupunând că  $D$  este o mulțime arbitrară nevidă,  $A : D \rightarrow \mathbb{R}$  este mărginită inferior, și  $B : D \rightarrow \mathbb{R}$  are proprietatea că

$$0 < c \leq B(x) \leq C \quad \text{pentru orice } x \in D,$$

pentru niște constante  $c, C \in \mathbb{R}$ , algoritmul lui Dinkelbach este:

**Algoritm 3.1.1** (Algoritmul lui Dinkelbach).

**Pasul 0 (inițializare)** Alegem un punct de plecare  $x_0 \in D$ , calculăm valoarea  $\lambda_0 = \frac{A(x_0)}{B(x_0)}$  și fixăm  $k = 1$ .



**Pasul  $k$  (pas ciclic pentru  $k \geq 1$ )** Se determină un punct  $x_k \in D$  astfel încât

$$A(x_k) - \lambda_{k-1}B(x_k) = m_k := \min_D (A - \lambda_{k-1}B),$$

se calculează

$$\lambda_k = \frac{A(x_k)}{B(x_k)}$$

și se trece la pasul  $k + 1$ .

**Teoremă 3.1.2.** *Algoritmul lui Dinkelbach este convergent iar dacă  $\lambda^* = \lim \lambda_k$  și  $x^* \in D$  este punctul pentru care*

$$A(x^*) - \lambda^*B(x^*) = \min_D (A - \lambda^*B),$$

atunci

$$\lambda^* = \frac{A(x^*)}{B(x^*)} = \min_D \frac{A}{B}. \quad (1.18)$$

Încheiem această secțiune reamintind principiul variațional al lui Ekeland și unele dintre consecințele sale (vezi, de exemplu, Ekeland [22], Frigon [27]), care se va dovedi a fi de o importanță deosebită pentru lucrarea noastră. De asemenea, reamintim condiția Palais-Smale (de compactitate), denumită în mod simplu (PS).

**Teoremă 3.1.3** (Ekeland). *Fie  $(X, d)$  un spațiu metric complet și fie  $E : X \rightarrow \mathbb{R}$  o funcțională inferior semicontinuuă și mărginită inferior. Atunci pentru orice  $\varepsilon > 0$  și  $u_0 \in X$ , există un punct  $u \in X$  astfel încât*

$$E(u) \leq E(v) + \varepsilon d(u, v) \quad \text{pentru orice } v \in X$$

și

$$E(u) \leq E(u_0) - \varepsilon d(u, u_0).$$

**Corolar 3.1.4.** *Fie  $(X, |\cdot|)$  un spațiu Banach și  $E : X \rightarrow \mathbb{R}$  o funcțională de clasă  $C^1$  mărginită inferior. Atunci pentru orice  $\varepsilon > 0$ , există un punct  $u \in X$  astfel încât*

$$E(u) \leq \inf_X E + \varepsilon, \quad |E'(u)| \leq \varepsilon$$

O funcțională  $E$  de clasă  $C^1$  definită pe un spațiu Banach satisface condiția (PS) dacă orice șir  $(x_k)$  cu

$$E(x_k) \rightarrow l \quad (l \in \mathbb{R}) \quad \text{și} \quad E'(x_k) \rightarrow 0$$

are un subșir convergent.

**Teoremă 3.1.5.** Fie  $(X, |\cdot|)$  un spațiu Banach și  $E : X \rightarrow \mathbb{R}$  o funcțională de clasă  $C^1$  mărginită inferior ce satisface condiția (PS). Atunci există un punct  $x^* \in X$  cu

$$E(x^*) = \inf_X E \quad \text{și} \quad E'(x^*) = 0.$$

## 3.2 Algoritmul lui Dinkelbach cu eroare fixă

În această secțiune, vom discuta cazul în care algoritmul lui Dinkelbach include o anumită eroare predeterminată  $\varepsilon > 0$ . În consecință, Algoritmul 3.1.1 se modifică după cum urmează:

**Algoritm 3.2.1** (Algoritmul lui Dinkelbach cu eroare fixă).

**Pasul 0 (inițializare)** Alegem un punct de plecare  $x_0 \in D$ , calculăm valoarea  $\lambda_0 = \frac{A(x_0)}{B(x_0)}$  și fixăm  $k = 1$ .

**Pasul  $k$  (pas ciclic pentru  $k \geq 1$ )** Se determină un punct  $x_k \in D$  astfel încât

$$A(x_k) - \lambda_{k-1}B(x_k) \leq \inf_D (A - \lambda_{k-1}B) + \varepsilon, \quad (1.19)$$

se calculează

$$\lambda_k = \min \left\{ \frac{A(x_k)}{B(x_k)}, \lambda_{k-1} \right\}$$

și se trece la pasul  $k + 1$ .

**Teoremă 3.2.2.** Dacă  $\tilde{\lambda} = \lim \lambda_k$  și  $\tilde{x} \in D$  este un punct pentru care

$$A(\tilde{x}) - \tilde{\lambda}B(\tilde{x}) \leq \inf_D (A - \tilde{\lambda}B) + \varepsilon,$$

atunci

$$\inf_D \frac{A}{B} \leq \tilde{\lambda} \leq \inf_D \frac{A}{B} + \frac{\varepsilon}{c} \quad (1.20)$$

și

$$\tilde{\lambda} - \frac{\varepsilon}{c} \leq \frac{A(\tilde{x})}{B(\tilde{x})} \leq \tilde{\lambda} + \frac{\varepsilon}{c}. \quad (1.21)$$

**Teoremă 3.2.3.** Fie  $D$  un spațiu metric,  $A$  și  $B$  funcții continue pe  $D$  și presupunem că are loc următoarea condiție de compacitate:

(C) orice șir  $(y_k)$  din  $D$  pentru care șirul  $(A(y_k)/B(y_k))$  este convergent are un subșir convergent în  $D$ .

Atunci există un punct  $\tilde{x} \in \overline{\{x_k\}}$  astfel încât  $\tilde{\lambda} = A(\tilde{x})/B(\tilde{x})$ .

### 3.3 Algoritmul lui Dinkelbach cu eroare convergentă la zero

În secțiunea anterioară am studiat algoritmul lui Dinkelbach cu eroare fixă  $\varepsilon > 0$ . În continuare vom vedea că dacă eroarea  $\varepsilon_k$ , acceptată la fiecare pas, converge la zero, atunci algoritmul converge către  $(\lambda^*, \tilde{x})$ , unde  $\lambda^*$  este infimumul lui  $A/B$  și acesta este atins sub ipoteza compactității enunțată în teorema 3.2.3. Noul algoritmul este:

**Algoritm 3.3.1** (Algoritmul lui Dinkelbach cu eroare convergentă la zero).

**Pasul 0 (inițializare)** Alegem un punct de plecare  $x_0 \in D$ , calculăm valoarea  $\lambda_0 = \frac{A(x_0)}{B(x_0)}$  și fixăm  $k = 1$ .

**Pasul  $k$  (pas ciclic pentru  $k \geq 1$ )** Se determină un punct  $x_k \in D$  astfel încât

$$A(x_k) - \lambda_{k-1}B(x_k) \leq \inf_D (A - \lambda_{k-1}B) + \varepsilon_k, \quad (1.22)$$

se calculează

$$\lambda_k = \min \left\{ \frac{A(x_k)}{B(x_k)}, \lambda_{k-1} \right\}$$

și se trece la pasul  $k + 1$ .

**Teoremă 3.3.2.** Dacă  $\tilde{\lambda} = \lim \lambda_k$  și  $\tilde{x} \in D$  este un punct pentru care

$$A(\tilde{x}) - \tilde{\lambda}B(\tilde{x}) \leq \inf_D (A - \tilde{\lambda}B) + \varepsilon,$$

atunci avem că

$$\tilde{\lambda} = \lambda^* = \inf_D \frac{A}{B} \quad (1.23)$$

și

$$\frac{A(\tilde{x})}{B(\tilde{x})} \leq \inf_D \frac{A}{B} + \frac{\varepsilon}{c}.$$

Reste de remarcat faptul că rezultatul din Teorema 3.2.3 rămâne valabil și în acest context. Mai precis, avem:

**Teoremă 3.3.3.** În condițiile teoremei 3.2.3, dacă  $(\lambda_k)$  și  $(x_k)$  sunt șirurile generate de algoritmul lui Dinkelbach cu eroare convergentă la zero iar  $\lambda^* = \lim \lambda_k$ , atunci există un punct  $x^* \in \overline{\{x_k\}}$  astfel încât

$$\lambda^* = \frac{A(x^*)}{B(x^*)} = \min_D \frac{A}{B}.$$

Mai mult, avem că

$$\inf_D (A - \lambda_k B) \rightarrow \inf_D (A - \lambda^* B) = 0 \quad \text{când } k \rightarrow \infty. \quad (1.24)$$

### 3.4 Algoritmul Dinkelbach-Ekeland

Următorul nostru obiectiv este să asigurăm condiția de compactitate de tipul Palais-Smale (condiția **(C)** din Teorema 3.2.3) pentru mulțimea necompactă  $D$ . Ne apropiem de această lucră dacă putem asigura proprietăți suplimentare șirului  $(x_k)$ . În acest scopul, vom prezenta o versiune modificată a algoritmului lui Dinkelbach folosind principiul variațional al lui Ekeland pentru a genera șirul  $(x_k)$ . Pentru aceasta fie  $(X, |\cdot|)$  un spațiu Banach și  $A, B : X \rightarrow \mathbb{R}$  două funcționale de clasă  $C^1$  astfel încât  $A$  este mărginită inferior iar  $B$  satisface

$$0 < c \leq B(x) \leq C \quad \text{pentru orice } x \in X.$$

Fie  $(\varepsilon_k)$  un șir descrescător la zero de numere reale pozitive. Atunci algoritmul Dinkelbach-Ekeland este:

**Algoritm 3.4.1** (Algoritmul Dinkelbach-Ekeland).

**Pasul 0 (inițializare)** Alegem un punct de plecare  $x_0 \in X$ , calculăm valoarea  $\lambda_0 = \frac{A(x_0)}{B(x_0)}$  și fixăm  $k = 1$ .

**Pasul  $k$  (pas ciclic pentru  $k \geq 1$ )** Folosind principiul lui Ekeland, determinăm un punct  $x_k \in X$  astfel încât

$$A(x_k) - \lambda_{k-1}B(x_k) \leq \inf_X (A - \lambda_{k-1}B) + \varepsilon_k, \quad (1.25)$$

$$|A'(x_k) - \lambda_{k-1}B'(x_k)| \leq \varepsilon_k$$

se calculează

$$\lambda_k = \min \left\{ \frac{A(x_k)}{B(x_k)}, \lambda_{k-1} \right\}$$

și se trece la pasul  $k + 1$ .

**Teoremă 3.4.2.** În condițiile enunțate anterior, dacă  $(\lambda_k)$  și  $(x_k)$  sunt șirurile generate de algoritmul Dinkelbach-Ekeland și  $\tilde{\lambda} = \lim \lambda_k$ , atunci

$$A(x_k) - \tilde{\lambda}B(x_k) \rightarrow \inf_X (A - \tilde{\lambda}B) \quad \text{și} \quad A'(x_k) - \tilde{\lambda}B'(x_k) \rightarrow 0. \quad (1.26)$$

Dacă în plus funcționala  $A - \tilde{\lambda}B$  satisface condiția (PS), atunci există un punct  $x^* \in \{x_k\}$  astfel încât

$$\tilde{\lambda} = \lambda^* = \frac{A(x^*)}{B(x^*)} = \min_X \frac{A}{B}.$$

### 3.5 Condiții suficiente pentru (PS)

În ultima secțiune a acestui capitol, prezentăm câteva condiții suficiente pentru ca o funcțională  $F$  să satisfacă condiția de compactitate (PS). Acestea necesită anumite proprietăți topologice asupra lui  $F'$  care sunt binecunoscute în analiza neliniară.

**Lemă 3.5.1.** *Fie  $(X, |\cdot|)$  un spațiu Hilbert și  $F : X \rightarrow \mathbb{R}$  o funcțională de clasă  $C^1$  cu următoarele proprietăți:*

- (i) *orice șir  $(x_k)$  pentru care șirul  $(F(x_k))$  converge este convergent;*
- (ii) *operatorul  $N := I - F'$  este complet continuu.*

*Atunci  $F$  satisface condiția (PS).*

**Lemă 3.5.2.** *Fie  $(X, |\cdot|)$  un spațiu Hilbert și  $F : X \rightarrow \mathbb{R}$  o funcțională de clasă  $C^1$  astfel încât*

- (ii\*) *operatorul  $N = I - F'$  este o contracție pe  $X$ .*

*Atunci  $F$  satisface condiția (PS).*

**Propoziție 3.5.3.** *Fie  $(X, |\cdot|)$  un spațiu Hilbert,  $A, B : X \rightarrow \mathbb{R}$  funcționale de clasă  $C^1$  astfel încât există constantele reale  $c, C$  cu  $0 < c \leq B \leq C$ . Atunci următoarele afirmații sunt adevărate:*

- (a) *Dacă  $A$  este coercivă iar operatorii  $I - A'$  și  $B'$  sunt complet continui, atunci pentru orice  $\lambda \in \mathbb{R}$ , funcționala  $A - \lambda B$  satisface condiția (PS).*
- (b) *Dacă operatorii  $I - A'$  și  $B'$  sunt  $L_A$ - și  $L_B$ -Lipschitz, cu  $L_A < 1$ , atunci funcționala  $A - \lambda B$  satisface condiția (PS) strict pentru orice  $\lambda$  cu  $|\lambda| < (1 - L_A) / L_B$ .*

În ceea ce privește algoritmul Dinkelbach-Ekeland, avem următorul rezultat final referitor la convergența sa.

**Teoremă 3.5.4.** *Fie  $(X, |\cdot|)$  un spațiu Hilbert și presupunem că au loc condițiile teoremei 3.4.2,  $(\lambda_k)$  și  $(x_k)$  sunt șirurile generate de algoritmul 3.4.1, iar  $\tilde{\lambda} = \lim \lambda_k$ . Atunci:*

- (a) *Dacă  $A$  e coercivă iar operatorii  $I - A'$  și  $B'$  sunt complet continui, atunci există un punct  $x^* \in \{x_k\}$  astfel încât*

$$\tilde{\lambda} = \lambda^* = \frac{A(x^*)}{B(x^*)} = \min_x \frac{A}{B}. \quad (1.27)$$

Capitolul 3. Algoritmi de aproximare de tip Dinkelbach pentru probleme fracționare

---

(b) Dacă operatorii  $I - A'$  și  $B'$  sunt  $L_A$ - respectiv  $L_B$ -Lipschitz cu  $L_A < 1$  și

$$\max \{ \lambda_0, -\lambda_{-1} \} < \frac{1 - L_A}{L_B}, \quad (1.28)$$

unde  $\lambda_{-1} = \inf_X A/B$ , atunci șirul  $(x_k)$  converge la  $x^*$  și relația (1.27) are loc.

---

## Capitolul 4

# Algoritmul lui Dinkelbach pe componente pentru probleme fracționare

---

Necesitatea ridicată de algoritmi de calcul pentru a aborda problemele de optimizare fracționară derivă dintr-o multitudine de scenarii practice. Aceste situații implică frecvent contexte în care obiectivul este optimizarea unei funcții fracționare, așa cum este evidențiat în lucrări precum Shen și Yu [75, 76], Elbenani și Ferland [21], și referințele din aceste lucrări. Prin urmare, aceste probleme au o relevanță substanțială în diverse domenii, inclusiv economie, planificare industrială, dezvoltare de strategii medicale și alte domenii conexe. Provocări similare sunt întâlnite și în diverse domenii matematice, cum ar fi teoria grafurilor și teoria jocurilor, așa cum este evidențiat în lucrările lui Stancu-Minasian [79], Stancu-Minasian și Tigan [80], și alte referințe citate de aceștia. În acest capitol al tezei, prezentăm un algoritm de tip Dinkelbach proiectat pentru a calcula puncte de minim parțial pentru problemele de optimizare fracționară.

Capitolul este împărțit în patru secțiuni. **Secțiunea 4.1** introduce cadrul general de lucru și oferă contextul necesar cititorului pentru a se familiariza cu problemele de optimizare fracționară în care funcția obiectiv (raport a două funcții) este definită pe produsul cartezian al două spații normate reale, respectiv  $X$  și  $Y$ . Secțiunea definește de asemenea foarte clar obiectivul acestei părți a tezei: determinarea așa-numitelor puncte de minim parțial. Acestea sunt puncte din  $X \times Y$  cu proprietatea că una dintre variabilele lor minimizează funcția obiectiv atunci când cealaltă variabilă este constantă.

În **Secțiunea 4.2** demonstrăm câteva rezultate referitoare la relația dintre punctele de minim global și parțial.

**Secțiunea 4.3** debutează prin introducerea algoritmului lui Dinkelbach pe componente (algoritmul 4.3.1) și prezintă câteva limitări ale acestuia.

În final, ultima **Secțiune 4.4** este dedicată convergenței algoritmului nostru. Secțiunea demonstrează că introducerea unor ipoteze suplimentare referitoare la spațiile și funcțiile implicate - cum ar fi continuitatea de tip Lipschitz, diferențiabilitatea Fréchet și coercivitatea - oferă o bază pentru determinarea condițiilor adecvate sub care algoritmul 4.3.1 este convergent către un minim parțial.

Rezultatele prezentate în această parte a tezei au fost incluse în lucrarea Günther, Orzan și Precup [36].

## 4.1 Problema generală de optimizare

În prima secțiune a acestui capitol, vom descrie problema generală de optimizare pe care o abordăm. Având acest scop în minte, vom considera pe tot parcursul capitolului că  $(X, |\cdot|_X)$  și  $(Y, |\cdot|_Y)$  sunt două spații normate reale,  $D_1 \subseteq X$ ,  $D_2 \subseteq Y$  sunt mulțimi nevide și  $A, B : D_1 \times D_2 \rightarrow \mathbb{R}$  sunt funcții astfel încât  $A$  este mărginită inferior și există  $c, C \in \mathbb{R}$  pentru care

$$0 < c \leq B(x, y) \leq C \quad \text{pentru orice } (x, y) \in D_1 \times D_2.$$

Problema de optimizare ce ne interesează este descrisă de

$$\frac{A(x, y)}{B(x, y)} \longrightarrow \min_{(x, y) \in D_1 \times D_2}. \quad (P)$$

Pentru această problemă  $(P)$ , de regulă se caută puncte  $(x^*, y^*) \in D_1 \times D_2$  astfel încât

$$\frac{A(x^*, y^*)}{B(x^*, y^*)} = \min_{(x, y) \in D_1 \times D_2} \frac{A(x, y)}{B(x, y)},$$

cu alte cuvinte  $(x^*, y^*)$  este minim global. Spre deosebire de această problemă, în cele ce urmează ne vom îndrepta atenția spre determinarea punctelor  $(x^*, y^*)$  din  $D_1 \times D_2$  cu proprietatea că

$$\frac{A(x^*, y^*)}{B(x^*, y^*)} = \min_{x \in D_1} \frac{A(x, y^*)}{B(x, y^*)}, \quad (1.29)$$

$$\frac{A(x^*, y^*)}{B(x^*, y^*)} = \min_{y \in D_2} \frac{A(x^*, y)}{B(x^*, y)}. \quad (1.30)$$

Punctele satisfăcând egalitățile (1.29) și (1.30) se numesc puncte de minim parțial sau minime parțiale pentru problema  $(P)$ .

Pentru a obține puncte de minim parțial, vom folosi o versiune modificată a algoritmului lui Dinkelbach, care se bazează pe rezolvarea, la fiecare pas iterativ, a două probleme parametrice de tipul



$$A(x, y) - \lambda B(x, y) \rightarrow \min_{x \in D_1}, \quad (P_y(\lambda))$$

$$A(x, y) - \lambda B(x, y) \rightarrow \min_{y \in D_2}, \quad (P_x(\lambda))$$

unde  $\lambda \in \mathbb{R}$  este un parametru. Procedeu nostru va genera trei șiruri  $(\lambda_k)$ ,  $(x_k)$  și  $(y_k)$ , unde  $x_k$  este o soluție a problemei  $(P_{y_{k-1}}(\lambda_{k-1}))$ ,  $y_k$  este o soluție a problemei  $(P_{x_k}(\lambda_{k-1}))$  iar

$$\lambda_k = \frac{A(x_k, y_k)}{B(x_k, y_k)}.$$

Folosind ipoteze adecvate în problema de optimizare fracționară, vom asigura convergența algoritmului și vom obține că punctul  $(x^*, y^*)$ , unde  $x^*$  și  $y^*$  sunt limitele șirurilor  $(x_k)$  și  $(y_k)$ , este minim parțial pentru funcționala  $\frac{A}{B}$ .

## 4.2 Relații între minime globale și parțiale

**Propoziție 4.2.1.** *Fie  $X$  și  $Y$  două spații reale normate și funcția  $f : X \times Y \rightarrow \mathbb{R}$ . Atunci:*

- 1° *Orice punct de minim global pentru  $f$  este minim parțial, însă reciproca nu este în general adevărată.*
- 2° *Dacă  $f$  este o funcție diferențiabilă Fréchet de clasă  $C^1$ , atunci orice punct de minim parțial este punct critic.*
- 3° *Dacă  $f$  este convexă, atunci  $(x, y)$  este minim global dacă vectorul nul aparține subgradientului lui  $f$  în punctul  $(x, y)$ , i.e.,  $0 \in \partial f(x, y)$ . În particular, dacă  $f$  este convexă și diferențiabilă Fréchet de clasă  $C^1$ , atunci orice minim parțial este minim global.*

**Propoziție 4.2.2.** *Dacă  $A, B : D_1 \times D_2 \rightarrow \mathbb{R}$  au variabile separate, adică*

$$A(x, y) = A_1(x) + A_2(y), \quad B(x, y) = B_1(x) + B_2(y)$$

*atunci orice minim parțial este și minim global pentru  $A(x, y)/B(x, y)$ .*

**Propoziție 4.2.3.** *Fie  $D_1 \subseteq \mathbb{R}^q$ ,  $D_2 \subseteq \mathbb{R}^p$  mulțimi nevide, deschise și convexe,  $A, B : D_1 \times D_2 \rightarrow \mathbb{R}$  funcții diferențiabile Fréchet, iar  $B$  pozitivă. Considerăm următoarele afirmații:*

1°  $(x^*, y^*)$  este minim global pentru  $\frac{A}{B}$ .

2°  $(x^*, y^*)$  este minim parțial pentru  $\frac{A}{B}$ .

3°  $(x^*, y^*)$  este punct critic pentru  $\frac{A}{B}$ , i.e.,  $\nabla \frac{A}{B}(x^*, y^*) = 0$ .

Atunci  $1^\circ \implies 2^\circ \implies 3^\circ$ . Dacă în plus are loc cel puțin una dintre următoarele afirmații:

(i)  $A$  este convexă și  $B$  este afină;

(ii)  $A$  este pozitivă și convexă, iar  $B$  este concavă,

atunci  $1^\circ \iff 2^\circ \iff 3^\circ$ .

### 4.3 Algoritmul lui Dinkelbach pe componente

În această secțiune vom prezenta algoritmul lui Dinkelbach pe componente, conceput pentru a puncte de minim parțial pentru problemele de optimizare fracționară.

**Algoritm 4.3.1** (Algoritmul lui Dinkelbach pe componente).

**Pasul 0 (inițializare)** Alegem un punct de plecare  $(x_0, y_0) \in D_1 \times D_2$ , calculăm valoarea

$$\lambda_0 := \frac{A(x_0, y_0)}{B(x_0, y_0)}$$

și fixăm  $k = 1$ .

**Pasul  $k$  (pas ciclic pentru  $k \geq 1$ )** Se determină un punct  $x_k \in D_1$  astfel încât

$$\min_{x \in D_1} [A(\cdot, y_{k-1}) - \lambda_{k-1}B(\cdot, y_{k-1})] = A(x_k, y_{k-1}) - \lambda_{k-1}B(x_k, y_{k-1}), \quad (1.31)$$

apoi determinăm un punct  $y_k \in D_2$  astfel încât

$$\min_{y \in D_2} [A(x_k, \cdot) - \lambda_{k-1}B(x_k, \cdot)] = A(x_k, y_k) - \lambda_{k-1}B(x_k, y_k), \quad (1.32)$$

se calculează

$$\lambda_k := \frac{A(x_k, y_k)}{B(x_k, y_k)} \quad (1.33)$$

și se trece la pasul  $k + 1$ .

**Propoziție 4.3.2.** *Problemele de minimizare date de (1.31) și (1.32) au soluții dacă cel puțin una dintre următoarele condiții este satisfăcută:*

- (a)  $D_1, D_2$  sunt compacte,  $A$  este inferior semicontinuă (i.s.) în raport cu fiecare variabilă iar  $B$  este continuă în ambele variabile.
- (b)  $D_1 = X$  și  $D_2 = Y$  sunt spații normate finit dimensionale,  $A$  este i.s. în raport cu fiecare variabilă, coercivă în  $x$  (i.e.,  $\lim_{|x|_X \rightarrow \infty} A(x, y) = \infty$  pentru orice  $y \in Y$ ), coercivă în  $y$  (i.e.,  $\lim_{|y|_Y \rightarrow \infty} A(x, y) = \infty$  pentru orice  $x \in X$ ) și  $B$  este continuă în ambele variabile.
- (c)  $D_1 = X, D_2 = Y$  sunt spații Banach reflexive,  $A$  este atât i.s. cât și convexă în ambele variabile, coercivă în  $x$ , coercivă în  $y$  și nenegativă, iar  $B$  este superior semicontinuă și concavă în ambele variabile.

## 4.4 Convergența algoritmului lui Dinkelbach pe componente

Ultima parte a acestui capitol oferă o serie de rezultate referitoare la convergența algoritmului nostru. Se arată că impunând ipoteze suplimentare asupra spațiilor și funcțiilor implicate, cum ar fi continuitatea de tip Lipschitz, diferențiabilitatea Fréchet și coercivitatea, algoritmul lui Dinkelbach pe componente este convergent către un punct de minim parțial.

**Teoremă 4.4.1.** *Șirul  $(\lambda_k)$  generat de algoritmul 4.3.1 este descrescător și convergent la  $\lambda^*$ .*

**Teoremă 4.4.2.** *Fie  $D_1, D_2$  mulțimi închise din spațiile normate  $X$  și  $Y$ ,  $A$  și  $B$  operatori continui, și*

$$x_k \rightarrow x^*, \quad y_k \rightarrow y^*. \quad (1.34)$$

*Atunci următoarele afirmații sunt adevărate:*

- (a) *Are loc egalitatea*

$$\lambda^* = \frac{A(x^*, y^*)}{B(x^*, y^*)}.$$

- (b) *Notând*

$$m_{k,1} := A(x_k, y_{k-1}) - \lambda_{k-1} B(x_k, y_{k-1}), \quad m_{k,2} := A(x_k, y_k) - \lambda_{k-1} B(x_k, y_k),$$

*avem că*

$$\lim_{k \rightarrow \infty} m_{k,1} = \lim_{k \rightarrow \infty} m_{k,2} = 0.$$

Capitolul 4. Algoritmul lui Dinkelbach pe componente pentru probleme fracționare

---

(c) punctul  $(x^*, y^*)$  este minim parțial pe  $D_1 \times D_2$  al funcției  $A(x, y) / B(x, y)$ .

În vederea stbilirii convergenței din (1.34), vom asigura întâi mărginirea șirurilor  $((x_k)$  și  $(y_k))$ . În acest scop, vom presupune că  $D_1 = X$ ,  $D_2 = Y$  sunt întreg spațiile normate, iar următoarea condiție are loc:

**(H1)** Funcționala  $A(x, y)$  este uniform coercivă în  $x$  în raport cu  $y$ , i.e., pentru orice  $M > 0$ , există  $l_M > 0$  astfel încât  $A(x, y) \geq M$  pentru  $|x|_X \geq l_M$  și pentru orice  $y \in Y$ .

**Propoziție 4.4.3.** *În condițiile ipotezei (H1), șirul  $(x_k)$  este mărginit.*

În următoarea parte a acestei secțiuni vom asigura convergența șirurilor  $(x_k), (y_k)$ , concluzionând astfel convergența algoritmului nostru 4.3.1. Pentru a realiza acest lucru, vom presupune că  $X$  și  $Y$  sunt spații Hilbert,  $D_1 = X$ ,  $D_2 = Y$ ,  $A$  și  $B$  sunt funcționale de clasă  $C^1$  ce satisfac anumite condiții de continuitate Lipschitz.

Notăm cu  $A'_x, A'_y, B'_x$  și  $B'_y$  derivatele parțiale Fréchet ale lui  $A$  și  $B$ , și presupunem că

**(H2)** Derivatele  $B'_x$  și  $B'_y$  sunt mărginite pe  $X \times Y$ .

De asemenea, definim operatorii

$$\begin{aligned} N_{11}(x, y) &:= c_1 x - A'_x(x, y), & N_{12}(x, y) &:= c_1 y - A'_y(x, y), \\ N_{21}(x, y) &:= c_2 x - B'_x(x, y), & N_{22}(x, y) &:= c_2 y - B'_y(x, y), \end{aligned}$$

unde

$$c_1 \geq \max\{1, \lambda_0\} + \lambda_0 c_2 \quad \text{și} \quad c_2 > 0. \quad (1.35)$$

Presupunem de asemenea că

**(H3)** Există constantele pozitive  $a_{ij}, b_{ij} \in \mathbb{R}$ ,  $i, j \in \{1, 2\}$ , astfel încât

$$\begin{aligned} |N_{11}(x, y) - N_{11}(\bar{x}, \bar{y})|_X &\leq a_{11}|x - \bar{x}|_X + a_{12}|y - \bar{y}|_Y, \\ |N_{12}(x, y) - N_{12}(\bar{x}, \bar{y})|_Y &\leq a_{21}|x - \bar{x}|_X + a_{22}|y - \bar{y}|_Y, \\ |N_{21}(x, y) - N_{21}(\bar{x}, \bar{y})|_X &\leq b_{11}|x - \bar{x}|_X + b_{12}|y - \bar{y}|_Y, \\ |N_{22}(x, y) - N_{22}(\bar{x}, \bar{y})|_Y &\leq b_{21}|x - \bar{x}|_X + b_{22}|y - \bar{y}|_Y \end{aligned}$$

pentru orice  $x, \bar{x} \in X$  și  $y, \bar{y} \in Y$ .

Capitolul 4. Algoritmul lui Dinkelbach pe componente pentru probleme fracționare

---

Notăm

$$c_{11} := a_{11} + b_{11}, \quad c_{12} := a_{12} + b_{12}, \quad c_{21} := a_{21} + b_{21}, \quad c_{22} := a_{22} + b_{22},$$
$$a := \frac{c_{12}c_{21}}{(1 - c_{11})(1 - c_{22})}$$

și presupunem că

**(H4)**  $c_{11} < 1$ ,  $c_{22} < 1$  și  $a < 1$ .

**Teoremă 4.4.4.** *În ipotezele (H1)-(H4), șirurile  $(x_k)$  și  $(y_k)$  sunt convergente.*

---

## Bibliografie

---

- [1] Aubin JP, Frankowska H. Set-valued analysis. Boston (MA): Birkhäuser; 1990.
- [2] Avriel M, Diewert WE, Schaible S, et al. Generalized concavity. New York (NY): Plenum Publishing Corporation; 1988.
- [3] Bagdasar O, Popovici N. Local maximizers of generalized convex vector-valued functions. *J. Nonlinear Convex Anal.* 2017;18:2229–2250.
- [4] Bagdasar O, Popovici N. Unifying local–global type properties in vector optimization. *J. Global Optim.* 2018;72:155–179.
- [5] Barbu V, Precupanu T. Convexity and optimization in Banach spaces. Alphen aan de Rijn (NL): Sijthoff and Noordhoff; 1978.
- [6] Benoist J, Borwein JM, Popovici N. A characterization of quasiconvex vector-valued functions. *Proc. Amer. Math. Soc.* 2003;131:1109–1113.
- [7] Berge C. Topological Spaces Including a Treatment of Multi-Valued Functions, Vector Spaces and Convexity. Edinburgh-London (EDI): Oliver & Boyd; 1963.
- [8] Bhatia D, Mehra A. Fractional programming involving set-valued functions. *Indian J. Pure Appl. Math.* 1998;29:525–539.
- [9] Borwein JM. Optimization with respect to partial orderings [dissertation]. Oxford: University of Oxford; 1974.
- [10] Boț RI, Csetnek ER. Proximal-gradient algorithms for fractional programming. *Optimization.* 2017;66(8):1383–1396.
- [11] Boț RI, Dao MN, Li G. Extrapolated proximal subgradient algorithms for nonconvex and nonsmooth fractional programs. *Mathematics of Operations Research.* 2021;47(3):2415–2443.

- [12] Boyd S, Parikh N, Chu E, Peleato B, Eckstein J. Distributed optimization and statistical learning via the alternating direction method of multipliers. *Found. Trends Mach. Learn.* 2011; 3(1):1–122.
- [13] Breckner WW, Kassay G. A systematization of convexity concepts for sets and functions. *J. Convex Anal.* 1997;4:109–127.
- [14] Cambini A, Martein L. Generalized convexity and optimization - Theory and applications, Berlin Heidelberg (DE): Springer; 2009.
- [15] Crouzeix JP, Ferland JA. Algorithms for generalized fractional programming. *Math. Program.* 1991;52:191–207.
- [16] Crouzeix JP, Ferland JA, Nguyen VH. Revisiting Dinkelbach-type algorithms for generalized fractional programs. *OPSEARCH.* 2008;45:97–110.
- [17] Crouzeix JP, Martínez-Legaz JE, Volle M. Generalized Convexity, Generalized Monotonicity: Recent Results. New York (NY): Springer; 1998.
- [18] Das K, Nahak C. Set-valued fractional programming problems under generalized cone convexity. *Opsearch* 2016;53:157–177.
- [19] Deutsch F, Singer I. On single-valuedness of convex set-valued maps. *Set-Valued Anal.* 1993;1:97–103.
- [20] Dinkelbach W. On nonlinear fractional programming. *Manage. Sci.* 1967;13:492–498.
- [21] Elbenani B, Ferland JA. Cell formation problem solved exactly with the Dinkelbach algorithm. Report CIRRELT-2012-07, University of Montreal. 2012.
- [22] Ekeland I. On the variational principle. *J. Math. Anal. Appl.* 1974;47:324–353.
- [23] Flores-Bazán F. Semistrictly quasiconvex mappings and non-convex vector optimization. *Math. Methods Oper. Res.* 2004;59:129–145.
- [24] Flores-Bazán F, Hernandez E. Optimality conditions for a unified vector optimization problem with not necessarily preordering relations. *Glob. Optim.* 2013; 56:299–315.
- [25] Flores-Bazán F, Vera C. Characterization of the nonemptiness and compactness of solution sets in convex and nonconvex vector optimization. *J. Optim. Theory Appl.* 2006;130:185–207.

- [26] Frenk JBG, Schaible S. Fractional programming. In: Hadjisavvas N, Komlósi S, Schaible S, editors. Handbook of generalized convexity and generalized monotonicity. New York (NY): Springer; 2005. p. 335–386.
- [27] Frigon M. On some generalizations of Ekeland’s principle and inward contractions in gauge spaces. *J. Fixed Point Theory Appl.* 2011;10:279–298.
- [28] Geissler B, Morsi A, Schewe L, et al. Penalty alternating direction methods for mixed-integer optimization: A new view on feasibility pumps. *SIAM J. Optim.* 2017;27(3):1611–1636.
- [29] Gerstewitz C. Nichtkonvexe Dualität in der Vektoroptimierung. *Wiss. Zeitschrift Tech. Hochsch.* 1983;25:357–364.
- [30] Gerth (Tammer) C, Weidner P. Nonconvex separation theorems and some applications in vector optimization. *J. Optim. Theory Appl.* 1990;67:297–320.
- [31] Goldstein T, O’Donoghue B, Setzer S, Baraniuk R. Fast alternating direction optimization methods. *SIAM J. Imaging Sci.* 2014;7(3):1588–1623.
- [32] Göpfert A, Riahi H, Tammer C, Zălinescu C. Variational methods in partially ordered spaces. New York (NY): Springer-Verlag; 2003.
- [33] Gorokhovich VV. Representations of affine multifunctions by affine selections. *Set-Valued Anal.* 2008;16:185–198.
- [34] Gorokhovich VV, Zabreiko PP. On Fréchet differentiability of multifunctions. *Optimization: A Journal of Mathematical Programming and Operations Research.* 2005;54(4-6):391–409.
- [35] Günther C, Orzan A, Popovici N. A new concept of semistrict quasiconvexity for vector functions, submitted 2023.
- [36] Günther C, Orzan A, Precup R. Componentwise Dinkelbach algorithm for nonlinear fractional optimization problems. *Optimization*, DOI: 10.1080/02331934.2023.2256750.
- [37] Günther C, Popovici N. Characterizations of explicitly quasiconvex vector functions w.r.t. polyhedral cones. *J. Nonlinear Convex Anal.* 2019;20:2653–2665.



- [38] Günther C, Popovici N. The role of nonlinear scalarization functions in characterizing generalized convex vector functions. *J. Appl. Numer. Optim.* 2019;1:325–333.
- [39] Günther C, Tammer C. Relationships between constrained and unconstrained multi-objective optimization and application in location theory. *Math. Methods Oper. Res.* 2016;84:359–387.
- [40] Günther C, Tammer C. On generalized-convex constrained multi-objective optimization. *Pure Appl. Funct. Anal.* 2018;3:429–461.
- [41] Hillier FS, Lieberman GJ. *Introduction to Operations Research*. San Francisco (US): Holden-Day; 1967.
- [42] Hiriart-Urruty JB. Generalized differentiability / duality and optimization for problems dealing with differences of convex functions. In: Ponsstein J, editors. *Convexity and duality in optimization. Lecture notes in economics and mathematical systems, vol 256*. Berlin, Heidelberg (DE): Springer; 1985. p. 37–70.
- [43] Jahn J. *Vector optimization - Theory, applications, and extensions*, 2nd ed. Berlin Heidelberg (DE): Springer; 2011.
- [44] Kassay G, Rădulescu VD. *Equilibrium problems and applications*. London (UK): Elsevier/Academic Press; 2019.
- [45] Khan AA, Tammer C, Zălinescu C. *Set-valued optimization: An introduction with applications*. Heidelberg (DE): Springer; 2015.
- [46] Khisty CJ, Lall BK. *Transportation Engineering: An Introduction*. Upper Saddle River (US): Prentice-Hall; 1998.
- [47] Kleinert T, Schmidt M. Computing feasible points of bilevel problems with a penalty alternating direction method. *INFORMS J. Comput.* 2021;33(1):198–215.
- [48] Kuroiwa D, Popovici N, Rocca M. A characterization of cone-convexity for set-valued functions by cone-quasiconvexity. *Set-Valued Var. Anal.* 2015;23:295–304.
- [49] La Torre D, Popovici N. Arcwise cone-quasiconvex multicriteria optimization. *Oper. Res. Lett.* 2010;38:143–146.

- [50] La Torre D, Popovici N, Rocca M. Scalar characterizations of weakly cone-convex and weakly cone-quasiconvex functions. *Nonlinear Anal.* 2010;72:1909–1915.
- [51] Le Thi HA, Pham DT. The DC (difference of convex functions) programming and DCA revisited with DC models of real world nonconvex optimization problems. *Annals of Operations Research.* 2005;133:23–46.
- [52] Le Thi HA, Pham DT. Open issues and recent advances in DC programming and DCA. *Journal of Global Optimization.* 2023. <https://doi.org/10.1007/s10898-023-01272-1>.
- [53] Luc DT. *Theory of vector optimization.* Berlin (DE): Springer; 1989.
- [54] Luc DT, Schaible S. Efficiency and generalized concavity. *J. Optim. Theory Appl.* 1997;94:147–153.
- [55] Luenberger DG. *Optimization by vector space methods.* New York (NY): John Wiley and Sons; 1969.
- [56] Nikodem K. K-convex and K-concave set-valued functions. *Lódz (PL): Zeszyty Nauk. Politech. Lódz. Mat.* 559, *Rozprawy Nauk.* 114; 1989.
- [57] Nikodem K, Popa D. On single-valuedness of set-valued maps satisfying linear inclusions. *Banach J. Math. Anal.* 2009;3:44–51.
- [58] de Oliveira W. The ABC of DC programming. *Set-Valued and Variational Analysis.* 2020;28:679–706.
- [59] Orzan A. A new class of fractional type set-valued functions. *Carpathian J. Math.* 2019;35:79–84.
- [60] Orzan A, Popovici N. Convexity-preserving properties of set-valued ratios of affine functions. *Stud. Univ. Babeş-Bolyai Math.* 2023;66:591–602.
- [61] Orzan A, Popovici N. Characterization of certain fractional-type set-valued functions. *Optimization.* DOI: 10.1080/02331934.2023.2174377.
- [62] Orzan A, Precup R. Dinkelbach type approximation algorithms for nonlinear fractional optimization problems, *Numerical Functional Analysis and Optimization.* 2023;44(9):954–969.
- [63] Popovici N. Explicitly quasiconvex set-valued optimization. *J. Global Optim.* 2007;38:103–118.

- [64] Popovici N. Pareto reducible multicriteria optimization problems. *Optimization* 2005;54:253–263.
- [65] Popovici N. Structure of efficient sets in lexicographic quasiconvex multicriteria optimization. *Oper. Res. Lett.* 2006;34:142–148.
- [66] Precup R. *Methods in nonlinear integral equations*. Dordrecht (DR): Springer; 2002.
- [67] Precup R. Nash-type equilibria and periodic solutions to nonvariational systems. *Adv. Nonlinear Anal.* 2014;3:197–207.
- [68] Rockafellar RT. *Convex analysis*. Princeton (NJ): Princeton University Press; 1970.
- [69] Ródenas RG, López ML, Verastegui D. Extensions of Dinkelbach’s algorithm for solving non-linear fractional programming problems. *Top* 1999;7:33–70.
- [70] Rothblum UG. Ratios of affine functions. *Math. Program.* 1985;32:357–365.
- [71] Schaible S. A survey of fractional programming. In: Schaible S, Ziemba WT, editors. *Generalized concavity in optimization and economics*. New York (NY): Academic Press; 1981. p. 417-440.
- [72] Schaible S. Bibliography in fractional programming. *Math. Methods Oper. Res.* 1982;26:211–241.
- [73] Schaible, S., Bicriteria quasiconcave programs, *Cahiers du Centre d’Etudes de Recherche Oprationnelle*. 1983;25:93–101.
- [74] Seto K, Kuroiwa D, Popovici N. A systematization of convexity and quasiconvexity concepts for set-valued maps, defined by  $l$ -type and  $u$ -type preorder relations. *Optimization*. 2018;67:1077–1094.
- [75] Shen K, Yu W. Fractional programming for communication systems—Part I: Power control and beamforming. *IEEE Transactions on Signal Processing* 2018;66(10):2616–2630.
- [76] Shen K, Yu W. Fractional programming for communication systems—Part II: Uplink scheduling via matching. *IEEE Transactions on Signal Processing* 2018;66(10):2631–2644.

- [77] Shi J. A combined algorithm for fractional programming. *Ann. Oper. Res.* 2001;103:135–147.
- [78] Singer I. *Duality for nonconvex approximation and optimization*. New York (NY): Springer; 2006.
- [79] Stancu-Minasian IM. *Fractional programming. Theory, methods and applications*. Dordrecht (NL): Kluwer; 1997.
- [80] Stancu-Minasian IM, Tigan S. Continuous time linear-fractional programming. The minimum-risk approach. *RAIRO Oper. Res.* 2000;34:397–409.
- [81] Tammer K, Tammer C, Ohlendorf E. *Multicriterial fractional optimization*, Berlin (BE): Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät II, Institut für Mathematik; 2005.
- [82] Tammer C, Weidner P. *Scalarization and separation by translation invariant functions*. Cham (CH): Springer; 2020.
- [83] Tammer C, Zălinescu C. Lipschitz properties of the scalarization function and applications. *Optimization*. 2010;59:305–319.
- [84] Tan DH. A note on multivalued affine mappings. *Studia Univ. Babeş-Bolyai Math.* 1988;33:55–59.
- [85] Toland JF. A duality principle for non-convex optimisation and the calculus of variations. *Arch. Rational Mech. Anal.* 1979;71:41–61.
- [86] Zălinescu C. *Convex analysis in general vector spaces*. Singapore (SG): World Scientific Publishing; 2002.